

Wissensbasierte Systeme

Master of Science

Prof. Dr. Rethmann

Fachbereich Ingenieurwissenschaften und Informatik
Hochschule Niederrhein

WiSe 2025/26

1 Übersicht

2 Geschichte und Anwendungen

3 Wissensrepräsentation

4 Zustandsraumsuche

5 Aussagenlogik

6 Prädikatenlogik

7 Prolog

- Wissensmodellierung und -verarbeitung: Wie Wissen bspw. in Form von Fakten, Regeln und Logik modelliert wird.
 - Ontologien
 - Semantische Netze
 - Logikbasierte Systeme
 - Expertensysteme
- maschinelles Lernen: Maschinen lernen aus Daten, Muster zu erkennen und Vorhersagen zu treffen.
 - Überwachtes Lernen (Supervised Learning)
 - Unüberwachtes Lernen (Unsupervised Learning)
 - Bestärkendes Lernen (Reinforcement Learning)
 - Deep Learning (Neuronale Netzwerke mit vielen Schichten)
- künstliche neuronale Netzwerke
 - Convolutional Neural Networks (CNNs) – Bildverarbeitung
 - Recurrent Neural Networks (RNNs) – Zeitreihen, Sprache
 - Transformer-Modelle – Sprachverarbeitung (z.B. GPT)

- Natural Language Processing (NLP)
 - Maschinelle Übersetzung
 - Spracherkennung
 - Textklassifikation und -zusammenfassung
 - Frage-Antwort-Systeme
 - Chatbots und Sprachassistenten
- Planung und Entscheidungsfindung: Automatisiertes Planen von Handlungen zur Zielerreichung.
 - Pfadplanung
 - Spieltheorie und Entscheidungsbäume
 - Multi-Agenten-Systeme
- und weitere ...

Dr. Thomas Röfer⁽¹⁾: Künstliche Intelligenz ist die falsche Übersetzung eines englischen Begriffs. „Intelligence“ meint ja auch Information. Es geht darum, auf künstliche Art Informationen zu beschaffen und bestimmte Aufgaben zu erledigen.

⁽¹⁾ Deutsches Forschungszentrum für Künstliche Intelligenz GmbH (DFKI), Interview taz, 2010.
<https://taz.de/Das-MontagsinterviewJedes-Lebewesen-ist-intelligenter/!409168/>

In dieser Veranstaltung:

- Geschichte und Anwendungen
- Wissensrepräsentation
- Zustandsraumsuche
- Aussagen- und Prädikatenlogik
- Einführung in PROLOG



- S. Russell, P. Norvig: *Artificial Intelligence – A Modern Approach*. Prentice Hall, 2002.
- George F. Luger: *Künstliche Intelligenz – Strategien zur Lösung komplexer Probleme*. Addison-Wesley, 2001.
- C. Beierle, G. Kern-Isberner: *Methoden wissensbasierter Systeme*. Vieweg Verlag, 2003.
- G. Görz, C.-R. Rollinger, J. Schneeberger (Hrsg.): *Handbuch der künstlichen Intelligenz*. 4. Auflage, Oldenbourg Verlag, 2003.
- U. Lämmel, J. Cleve: *Lehr- und Übungsbuch Künstliche Intelligenz*. Fachbuchverlag Leipzig, 2001.
- J. Heinsohn, R. Socher-Ambrosius: *Wissensverarbeitung – Eine Einführung*. Spektrum Akademischer Verlag, 1999.

- Uwe Schöning: *Logik für Informatiker*. Spektrum Akademischer Verlag, 2000.
- Ivan Bratko: *PROLOG – Programming for Artificial Intelligence*. 3rd edition, Addison-Wesley, 2000.
- Richard S. Sutton and Andrew G. Barto. *Reinforcement learning - an introduction*. Adaptive computation and machine learning. MIT Press, 1998.
- Csaba Szepesvári. *Algorithms for Reinforcement Learning*. Synthesis Lectures on Artificial Intelligence and Machine Learning. Morgan & Claypool Publishers, 2010.
- I. Gerdes, F. Klawonn, R. Kruse: *Evolutionäre Algorithmen*. Vieweg Verlag, 2004.
- Hans-Jürgen Zimmermann: *Operations Research*. Vieweg Verlag, 2005.
- Andreas Zell: *Simulation Neuronaler Netze*. Addison-Wesley, 1994.

1 Übersicht

2 Geschichte und Anwendungen

3 Wissensrepräsentation

4 Zustandsraumsuche

5 Aussagenlogik

6 Prädikatenlogik

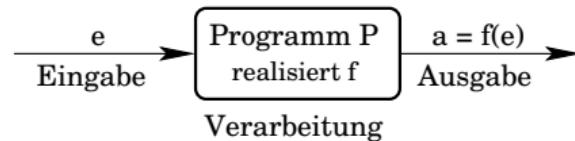
7 Prolog

Ein Programm P realisiert eine Funktion f , so dass zu einer Eingabe e eine Ausgabe $a = f(e)$ berechnet wird. → EVA-Prinzip: Eingabe, Verarbeitung, Ausgabe.

Das Programm P und damit die Funktion f wird explizit in einer Programmiersprache wie C# oder Java implementiert. → imperative Programmierung

Jedes Programm berechnet also eine Funktion $f : \mathbb{D} \rightarrow \mathbb{W}$, wobei \mathbb{D} der Definitionsbereich und \mathbb{W} der Wertebereich ist.

Funktion f bildet Argument $z \in \mathbb{D}$ auf den Wert $f(z) \in \mathbb{W}$ ab. Notation: $z \mapsto f(z)$



Beispiel: Sortiere die gegebenen Zahlen x_1, \dots, x_n aufsteigend. Dann bildet f eine Eingabe $e = (x_1, \dots, x_n)$ auf eine Ausgabe $a = f(e) = (x_{\pi(1)}, \dots, x_{\pi(n)})$ ab, wobei π eine Permutation ist und $x_{\pi(i)} \leq x_{\pi(j)}$ für $1 \leq i < j \leq n$ gilt.

Algorithmen wie Quicksort, Mergesort oder Heapsort realisieren die Funktion f , indem sie beschreiben, WIE eine Zahlenfolge sortiert wird.

Was tun wir aber, wenn wir die zu realisierende Funktion f nicht kennen? Wie soll f dann als Programm realisiert werden?

Wie sieht eine Funktion f aus, die bei Eingabe eines Bildes, bspw. bestehend aus 28×28 Pixeln mit bis zu 256 Grauwerten pro Pixel, die dort enthaltenen Ziffern⁽²⁾ erkennt? Es soll also eine Funktion $f : \{0, \dots, 255\}^{28 \times 28} \rightarrow \{0, 1, \dots, 9\}$ berechnet werden.

Antworten auf solche Fragen liefert das Machine Learning, ein Teilbereich der künstlichen Intelligenz.

Mittels neuronaler Netze lässt sich das Problem der Ziffernerkennung heute sehr gut lösen. Im wesentlichen basiert die gute Erkennung darauf, dass sich die Netze erinnern, eine ähnliche Ziffer schon einmal während des Trainingsprozesses gesehen zu haben und daher der Eingabe eine Ziffer zuordnen können.

Wie könnte mathematisch ein Maß für die Ähnlichkeit zweier Ziffern definiert werden?

⁽²⁾ siehe bspw. den MNIST-Datensatz, <https://de.wikipedia.org/wiki/MNIST-Datenbank>

Was können Menschen besser als Maschinen?

Bilder erkennen, Texte übersetzen, Sprache verarbeiten, Spiele spielen, Planen, Beweisen, Schlussfolgern, Lernen, neue Situationen erfassen und beurteilen, usw.

Menschen lernen durch Beispiele bzw. Analogie und nutzen Ähnlichkeiten: Vorhandenes Wissen wird an neue Situationen angepasst. Ist das Intelligenz?

Voraussetzung ist, dass für ähnliche Situationen bereits Problemlösungen bekannt sind. Es wird also eine große Menge an Fällen bzw. Beispielen benötigt.

Wenn eine neue Situation N ähnlich zu einer anderen, bereits bekannten Situation A ist, und diese Situation A früher mit einem Verfahren V gelöst wurde, müssen zwei Fälle unterschieden werden:

- Falls V für A erfolgreich war, dann wende V auf N an,
- sonst wähle ein anderes Verfahren oder passe V an, sodass es auf N angewendet werden kann.

Beim fallbasierten Schließen besteht die Wissensbasis nicht aus generischen Regeln, sondern aus einer Sammlung von Fällen, in denen spezifische frühere Erfahrungen gespeichert sind.

Neue Probleme, mit denen das System konfrontiert wird, werden dadurch gelöst, dass der relevanteste Fall aus der Falldatensammlung heraus gesucht wird und dessen Lösung in geeigneter Form auf das neue Problem übertragen wird.

Schließen kann als erinnerungsbasierter Prozess verstanden werden, wie wir bereits bei den neuronalen Netzen gesehen haben.

Dazu müssen Ähnlichkeiten bestimmt werden, wozu wir wieder Funktionen angeben müssen! Sind diese Funktionen nicht bekannt, setzen wir wieder Methoden des Machine Learnings ein.

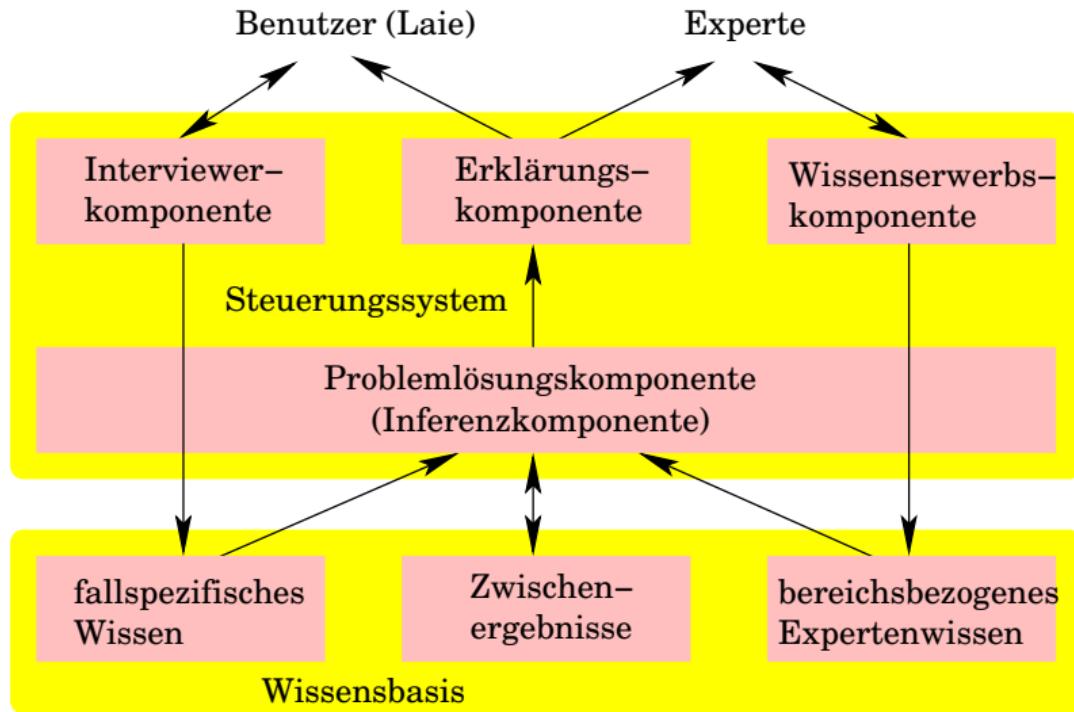
Was ist Wissen?

- **Philosophie:** Wissen ist wahrer, gerechtfertigter Glaube.
- **Wissensrepräsentation:** Wissen ist Information über die Welt, ohne Anspruch auf deren Wahrheitsgehalt.
- Beispiel: Im Mittelalter wusste man, dass die Erde eine Scheibe ist!

Im weiteren Sinn ist jede Programmierung **Wissensverarbeitung**: Jedes Programm kodiert und verarbeitet Wissen. Im engeren Sinn wird Wissensverarbeitung der KI zugeordnet.

- Artificial intelligence (AI) is the study of any device that perceives its environment and takes actions that maximize its chance of successfully achieving its goals. or: AI is whatever hasn't been done yet.
- Machine learning (ML) is the study of computer algorithms that improve automatically through experience.
- Expert system is a computer system that emulates the decision-making ability of a human expert. Expert systems are designed to solve complex problems by reasoning through bodies of knowledge. (wikipedia)

Trennung von Wissen und Verarbeitung:



Steuerungssystem:

- **Problemlösungskomponente (Inferenzkomponente):** Interpretiert das Expertenwissen, um eine Lösung des vom Benutzer gegebenen Problems zu finden.
- **Interviewerkomponente:** Führt den Benutzerdialog, liest die Messdaten ein und stellt fallspezifisches Wissen dar.
- **Erklärungskomponente:** Liefert dem Benutzer eine Begründung für die Problemlösung. Manche Menschen akzeptieren die von einer Maschine vorgeschlagene Lösung nur dann, wenn das Programm erklärt, wie es zu der Lösung gekommen ist.
- **Wissenserwerbskomponente:** Aufbau und Wartung des Fachwissens.

Wissensbasis:

- *Expertenwissen:* Fachwissen aus dem Anwendungsbereich, häufig in Form von Regeln.
- *fallspezifisches Wissen:* Daten, die der Anwender zu seinem konkreten Problem beisteuert, häufig in Form von Fakten.
- *Zwischenergebnisse / Problemlösungen:* Werden von der Inferenzkomponente erzeugt.

Vorteil dieser Architektur:

- Die Wissensbasis ist austauschbar!

Arten von Wissen:

- Relationales Wissen spielt im Alltag eine große Rolle:
 - Person X ist mit Y verheiratet.
 - Der Motor ist ein Teil vom Auto.
- Vererbung von Eigenschaften:
 - Der Golf ist ein Auto. Ein Auto hat einen Motor.
 - ⇒ Der Golf hat einen Motor.
- Prozedurales Wissen schreibt eine Folge von Aktionen vor:
 - Eröffnungen beim Schach
 - das Betanken eines Autos
 - das Betreten eines Restaurants
- Logisches Wissen:
 - Jeder Mensch ist sterblich. Sokrates ist ein Mensch.
 - ⇒ Sokrates ist sterblich.

- Zeitabhängiges Wissen

- „Es ist kalt“ ist nicht immer richtig.
- ... täglich außer Montags ...
- Devisenkurse, Füllstände usw. sind zeitabhängig.
- Beim Planen sind zeitliche Relationen wichtig: *vor*, *nach*, ...
→ Temporallogik, Situationskalkül

- Unvollständiges Wissen

- Eine Kamera erfasst nicht die gesamte Umgebung. Was liegt hinter dem nächsten Hügel?
- Nicht alle Zusammenhänge in der Medizin sind bekannt.
→ Fehlende Informationen werden durch Annahmen ersetzt.

- Vages Wissen

- unscharf: Der Mann ist groß. Das Wetter ist gut.
- unsicher: Temperatursensor hat Toleranz von $\pm 1^{\circ}\text{C}$.
→ Fuzzy-Logik, Sicherheitsfaktoren

Darstellung von Wissen:

- Neuronale Netze
- Regeln
- Semantische Netze und Frames
- Aussagen- und Prädikatenlogik
- Skripte
- Bayessche Netze

Anforderungen an die Wissensrepräsentation:

- Wissen ist leicht überprüfbar und aktualisierbar.
- Ableiten neuen Wissens / Schlussfolgern ist möglich.
- Hypothesen können bestätigt oder widerlegt werden.

Warum ist die Darstellung von Wissen wichtig?

- Wissen muss effizient verarbeitet werden.
- Qualität der Antwort muss den Erfordernissen entsprechen.
- Beispiel: Rechnen mit römischen Zahlen vs. indischen Zahlen.

Closed-World-Assumption:

- Nur positive Fakten werden explizit gespeichert. Fehlende Information wird als Falschheit der Information gedeutet.
- Oft richtig und vernünftig, um Wissensbasis klein zu halten:
 - Wenn kein Direktflug von Bonn nach London in der Datenbank gespeichert ist, dann gibt es auch keinen.
 - Die Kannibalen⁽³⁾ dürfen nicht unter Drogen gesetzt werden und es gibt auch keine Brücke über den Fluss.

⁽³⁾Drei Missionare und 3 Kannibalen wollen einen Fluss überqueren. Das Ruderboot für die Überfahrt kann nur 2 Personen aufnehmen. Es dürfen nie mehr Kannibalen als Missionare an einem Ort sein, sonst wird es unschön.

Anwendung bei Problemen, die keine algorithmische Lösung haben, z.B. einige Suchprobleme mit exponentiell großem Lösungsraum.

- Logik-Rätsel Sudoku: Fülle das Gitter mit den Ziffern 1 bis 9 so, dass jede Ziffer in jeder Spalte, in jeder Zeile und in jedem Block genau einmal vorkommt.
- Zahlenrätsel: SEND + MORE = MONEY
- Spiele: Tic-Tac-Toe, Mühle, Schach, Go

Übung 1. Schreiben Sie ein Programm, das ein gegebenes $n \times n$ -Sudoku für $n = 9, 16, 25, 36, 49$ mittels Backtracking löst. Welche Laufzeiten ergeben sich für große Werte von n ?

3								
			1	9	5			
		9	8					6
8					6			
4						3		1
					2			
	6						2	8
			4	1	9			5
							7	

Methode der Wissensbasierten Systeme: Einsatz von Wissen!

- Erfolg ist nicht garantiert, aber oft besser als ohne Wissen.
- Wissen ist anwendungsspezifisch, oft als Heuristik realisiert.

Viele bekannte Spiele sind schwer:

- Sudoku ist NP-vollständig: Yato und Seta (2003)
- Mastermind ist NP-vollständig: Stuckman und Zhang (2006)
- Minesweeper ist NP-vollständig: Kaye (2000)
- Brett-Solitär ist NP-vollständig: Uehara und Iwata (1990)
- Sokoban ist PSPACE-vollständig: Dor und Zwick (1999)
- Rush Hour ist PSPACE-vollständig: Flake und Baum (2002)

Eine schöne Übersicht über die Komplexität von Spielen gibt das Papier⁽⁴⁾ von G. Kendall, A.J. Parkes, K. Spoerer: A Survey of NP-Complete puzzles. ICGA Journal. 2008 (31). 13-34.

⁽⁴⁾https://www.researchgate.net/publication/220174445_A_Survey_of_NP-Complete_puzzles
Wissensbasierte Systeme Geschichte und Anwendungen 22 / 889

Reduktion des Suchraums durch Wissen:

Streiche in jedem Feld aus der Liste der prinzipiell möglichen Zahlen alle die Zahlen heraus, die bereits in der jeweiligen Zeile, der Spalte oder in dem Unterblock vorkommen.

4			2	7		6		
7	9	8	1	5	6	2	3	4
	2		8	4				7
2	3	7	4	6	8	9	5	1
8	4	9	5	3	1	7	2	6
5	6	1	7	9	2	8	4	3
	8	2		1	5	4	7	9
	7			2	4	3		
		4		8	7			2

⇒

4	¹ 5		3	2	7	3	6	¹ 8 9	⁵ 8
7	9	8	1	5	6	2	3	4	
¹ 6	2	³ 5 6	8	4	³ 1 5	¹ 9			7
2	3	7	4	6	8	9	5	1	
8	4	9	5	3	1	7	2	6	
5	6	1	7	9	2	8	4	3	
³ 6	8	2	³ 6	1	5	4	7	9	
¹ 6 ₉	7	⁵ 6	⁶ 9	2	4	3	¹ 8 ₆	⁵ 8	
¹ 6 ₉	3	1 5	4	³ 6 ₉	8	7	¹ 5	¹ 6	2

Einsatz von Wissen

Naked Single - einzig möglicher Wert: Das Kästchen muss diesen Wert annehmen, da alle anderen Werte bereits vergeben sind.

1	5	3	3	2				4
2	9		8	5	3	6	7	
8								
2	3	4	1 3	6	7			
5	6		8					
8								
	1					5	9	
		2			3			
9	7					2		
			1			6		
	8	5	3	9		1		
4				6				5

Hidden Single - einzig möglicher Ort: Das Kästchen muss diesen Wert annehmen, da alle anderen Kästchen diesen Wert nicht annehmen können.

							5	
1	6			9				
		9			6	4		
					5	6	1	
					7	9	5	6
					7	8	7	8
4				2	5	6	1	
				3	4	1	6	5
			2		8	9		
		1		2	5			3
7				1				9

Einsatz von Wissen

9	8	4	1 2	1 2	3	1 3	6	5	7	6	7	5
3				1		3	1	3				
7		6	2	5	7 8	6	9	4		7 8 9		
5	3	5 6	1	9	7 8	4	5	3	6		2	
7	7						7 8					
5	4 5	6	1 4	9	7	2	3	4 5	8			
8	8	8										
1												
5	4 5	3	6	1 4	2	5	9	7 8	4 5	7 8 9		
7	8	7	8	8	2	5	9	7 8	4 5	7 8 9		
2	4	9	4 8	3	5	6	1	4	7 8			
7												
1	9	5	7	6	8	4	2	3				
4	2	7	3	5	1	8	9	6				
6	3	8	4 2	4 2	9	7	5	1				

3	4	1	5	1 2	5	5	8 9	6	1 2	5	7	1 2
1	5 6	8	9	1 2	5 6	4 5	4 5	1	5	9	9 3	1 2
7				7	7	7	7	7	7	7	7	4
1		1			1	4 5	3	1	5	4 5	6	1
5	5	5	7	7	8	7 8	7 9	7	9	4 5	6	8
8												
2	2 3	3	5	5	6	4 5 6	5	2 3	2	2 3		
4	4 5 6	5 6	5 6	8	7 8	7 8	7 9	1	5	4 6	4	6
5	8							7	7	7	7	9
1	2											1 2
9	7	3	6	4	8	5	4	8	5	6	7	5
7												
1	3	1	3	5	6	4 5 6	5	1	3	1	3	1
4	5 6	5 6	5 6	8	7 8	7 8 9	7 8 9	2	4	6	4	6
5	8								7	7	7	9
7												
1	2	1 2 3	1	3	1	3	1	1	2 3	1 2	1 2 3	
4	5 6	5 6	4 5 6	4 5 6	8	9	7	4 5	5	4 6	4	6
5	7							7	7	7	7	
7												
1	2	1 2 3	1	3	6	4 5	6	1 2 3	1	2 3	1 2	1 2 3
4	5	5	4 5	7	7	6	7	6	4 5	8	4	6
5	7								7	7	7	
7												
1		1						9	2	3	7	8 5
4	6											
6	3	8	4 2	4 2	9	7	5	1				

Locked Candidates: Wenn in einem Block alle Kandidaten einer bestimmten Ziffer auf eine Zeile oder Spalte beschränkt sind, kann diese Ziffer nicht außerhalb dieses Blocks in dieser Zeile oder Spalte erscheinen.

Quelle: <http://hodoku.sourceforge.net/>

Naked Pair: Kommen in zwei Zellen eines Bereichs ausschließlich die zwei gleichen Werte vor, dann müssen sich diese zwei Zellen diese zwei Werte teilen.

4			2	7		6		
7	9	8	1	5	6	2	3	4
	2		8	4				7
2	3	7	4	6	8	9	5	1
8	4	9	5	3	1	7	2	6
5	6	1	7	9	2	8	4	3
3	6	8	2	3	1	5	4	7
1	6	7	5	6	2	4	3	1
9	1	3	6	5	8	7	5	6
1	3	5	4	3	8	7	5	2

Hidden Pair: Kommt ein Wertepaar nur in zwei Zellen vor, dann müssen sich diese beiden Zellen diese Werte teilen, da keine andere Zelle sie übernehmen kann.

	6		3	9		1		
		3	1	5			9	
1	9		4	2	6	3		
8	3		5	7	9	4	1	2
9				6	1	7	3	5
	5	1		4	3	7	6	9
4	1	9	6	3	5	8	2	7
	2		9	8	4	5		1
	8		7	1	2	9	4	

Weitere Methoden zur Einschränkung des Suchraums bei Sudoku finden Sie bspw. unter: www.sudokuoftheday.com/pages/techniques-overview.php

Übung 2. Bauen Sie obige Techniken in Ihren Sudoku-Solver ein und vergleichen Sie die Laufzeiten der beiden Versionen.

Zahlenrätsel: Wissen über Addition beschränkt den Suchraum.

- Bei Addition zweier Ziffern ist der Übertrag 1.

$$\begin{array}{r} \text{S} \quad \text{E} \quad \text{N} \quad \text{D} \\ + \text{M} \quad \text{O} \quad \text{R} \quad \text{E} \\ \hline \text{M} \quad \text{O} \quad \text{N} \quad \text{E} \quad \text{Y} \end{array} \rightarrow \begin{array}{r} \text{S} \quad \text{E} \quad \text{N} \quad \text{D} \\ + \text{1} \quad \text{O} \quad \text{R} \quad \text{E} \\ \hline \text{1} \quad \text{O} \quad \text{N} \quad \text{E} \quad \text{Y} \end{array}$$

Zahlenrätsel: Wissen über Addition beschränkt den Suchraum.

- Bei Addition zweier Ziffern ist der Übertrag 1.

$$\begin{array}{r} \text{S} \quad \text{E} \quad \text{N} \quad \text{D} \rightarrow \\ + \quad \text{M} \quad \text{O} \quad \text{R} \quad \text{E} \\ \hline \text{M} \quad \text{O} \quad \text{N} \quad \text{E} \quad \text{Y} \end{array} \quad \begin{array}{r} \text{S} \quad \text{E} \quad \text{N} \quad \text{D} \\ + \quad \text{1} \quad \text{O} \quad \text{R} \quad \text{E} \\ \hline \text{1} \quad \text{O} \quad \text{N} \quad \text{E} \quad \text{Y} \end{array}$$

- S muss gleich 8 oder 9 sein, da sonst kein Übertrag erzielt würde. Wir setzen zunächst S auf 9.

$$\begin{array}{r} \text{S} \quad \text{E} \quad \text{N} \quad \text{D} \rightarrow \\ + \quad 1 \quad \text{O} \quad \text{R} \quad \text{E} \\ \hline 1 \quad \text{O} \quad \text{N} \quad \text{E} \quad \text{Y} \end{array} \quad \begin{array}{r} 9 \quad \text{E} \quad \text{N} \quad \text{D} \\ + \quad 1 \quad \text{O} \quad \text{R} \quad \text{E} \\ \hline 1 \quad \text{O} \quad \text{N} \quad \text{E} \quad \text{Y} \end{array}$$

Zahlenrätsel: Wissen über Addition beschränkt den Suchraum.

- Bei Addition zweier Ziffern ist der Übertrag 1.

$$\begin{array}{r} \begin{array}{ccccc} S & E & N & D & \rightarrow \\ + & M & O & R & E \\ \hline M & O & N & E & Y \end{array} & \begin{array}{ccccc} S & E & N & D & \\ + & \textcolor{blue}{1} & O & R & E \\ \hline \textcolor{blue}{1} & O & N & E & Y \end{array} \end{array}$$

- S muss gleich 8 oder 9 sein, da sonst kein Übertrag erzielt würde. Wir setzen zunächst S auf 9.

$$\begin{array}{r} \begin{array}{ccccc} S & E & N & D & \rightarrow \\ + & 1 & O & R & E \\ \hline 1 & O & N & E & Y \end{array} & \begin{array}{ccccc} 9 & E & N & D & \\ + & 1 & O & R & E \\ \hline 1 & O & N & E & Y \end{array} \end{array}$$

- Dann muss O gleich 0 sein. (1 ist bereits durch M belegt!)

$$\begin{array}{r} \begin{array}{ccccc} 9 & E & N & D & \rightarrow \\ + & 1 & O & R & E \\ \hline 1 & O & N & E & Y \end{array} & \begin{array}{ccccc} 9 & E & N & D & \\ + & 1 & \textcolor{blue}{0} & R & E \\ \hline 1 & \textcolor{blue}{0} & N & E & Y \end{array} \end{array}$$

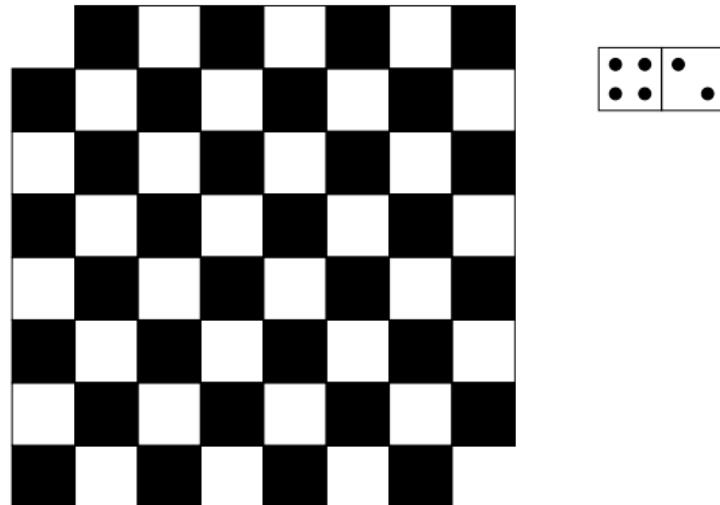
Zahlenrätsel: Was bringt der Einsatz von Wissen?

- Wir haben insgesamt 8 verschiedene Buchstaben im obigen Rätsel.
- Jeder Buchstabe stellt eine Ziffer dar, wobei verschiedene Buchstaben auch verschiedene Ziffern darstellen.
- Wir haben also im ursprünglichen Problem $10 \cdot 9 \cdot 8 \cdot 7 \cdot \dots \cdot 3 = 1.814.400$ Kombinationen zu testen.
- Durch den Einsatz des Wissens legen wir die Werte von M und O eindeutig fest, für S verbleiben nur 2 Möglichkeiten.

→ Damit reduzieren wir den Suchraum durch den Einsatz von Wissen auf $2 \cdot 7 \cdot 6 \cdot 5 \cdot \dots \cdot 3 = 5.040$ Kombinationen.

Explizites Wissen über einen Aufgabenbereich verkürzt die Suche!

Plazierung von Dominosteinen auf einem Schachbrett, bei dem zwei diagonal gegenüberliegende Eckfelder fehlen.



Frage: Kann man das Schachbrett so mit Dominosteinen bedecken, dass alle Felder belegt sind, keine Dominosteine über den Rand herausragen und sich keine Dominosteine überlappen?

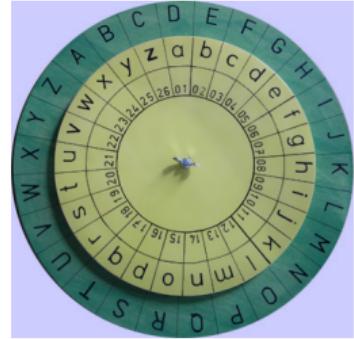
Lösungsmöglichkeiten:

- Vollständige Suche:
Teste alle Möglichkeiten, Dominosteine auf das Brett zu legen. Stop, sobald alle Felder belegt sind oder falls alle Möglichkeiten fehlgeschlagen sind.
- Reduktion des Suchraums durch Symmetriebetrachtungen oder Heuristiken.
- Einsatz von Wissen:
Das Brett hat 30 weiße und 32 schwarze Felder. Jeder Stein bedeckt genau ein schwarzes und ein weißes Feld. \Rightarrow Es gibt keine Lösung für das Problem!

Der Einsatz von Wissen kann eine Suche enorm verkürzen!

Cäsar-Code: Ersetzte jeden Buchstaben des Textes durch den Buchstaben, der im Alphabet n Stellen danach kommt.

Beispiel: Für $n = 2$ wird aus dem Klartext ELEFANTEN der verschlüsslete Text GNGHCPVGP.



Codebrechen mittels Häufigkeitstabelle:

Buchstabe	Häufigkeit
E	17,40%
N	9,78%
I	7,55%
S	7,27%
R	7,00%

Paare	Häufigkeit
ER	4,09%
EN	4,00%
CH	2,42%
DE	1,93%
EI	1,87%

Codierter Text: FKGUKUVGKPGIGJGKOGPCEJTKEJV

Klartext: ??

Buchstabe	Anzahl	relative Häufigkeit
G	6	23,1%
K	5	19,2%
J	3	11,5%
C	2	7,7%
U	2	7,7%

Vermutlich G → E: DIESISTEINEGEHEIMENACHRICHT

richtige Kryptographie: Prof. Dr. Nils Kopal, <https://www.de-crypt.org/>

Als Fazit kann man vielleicht festhalten: mehr Wissen → weniger Suchen

Was ist künstliche Intelligenz?

- 1955 John McCarthy:

Ziel der KI ist es, Maschinen zu entwickeln, die sich verhalten, als verfügten sie über Intelligenz.

- 1991 Encyclopedia Britannica:

KI ist die Fähigkeit digitaler Computer oder computergesteuerter Roboter, Aufgaben zu lösen, die normalerweise mit den höheren intellektuellen Verarbeitungsfähigkeiten von Menschen in Verbindung gebracht werden.

- 1983 Elaine Rich:

Forschung darüber, wie Computer Dinge machen, die Menschen derzeit noch besser beherrschen.

Heute:

- KI ist die Untersuchung von Berechnungsverfahren, die es ermöglichen, wahrzunehmen, zu schlußfolgern und zu handeln.
- Ermitteln, welche Annahmen über die Repräsentation und Verarbeitung von Wissen und den Aufbau von Systemen die verschiedenen Aspekte der Intelligenz erklären können.

⇒ Synthese vor Analyse: Lerne menschliche Intelligenz zu verstehen durch die Konstruktion intelligenter Systeme.

Vorherrschender Gedanke:

- Intelligenz emergiert aus der Interaktion vieler einfacher Prozesse im Zusammenspiel und
- Prozessmodelle intelligenten Verhaltens können mit Hilfe des Computers im Detail untersucht werden.

1 Übersicht

- Lernen durch Belohnung
- Planen

2 Geschichte und Anwendungen

- Turing-Test
- neuronale Netze
- Agenten
- Entscheidungsbäume
- Fallbasiertes Schließen
- Sequentielle Entscheidungsprobleme

3 Wissensrepräsentation

4 Zustandsraumsuche

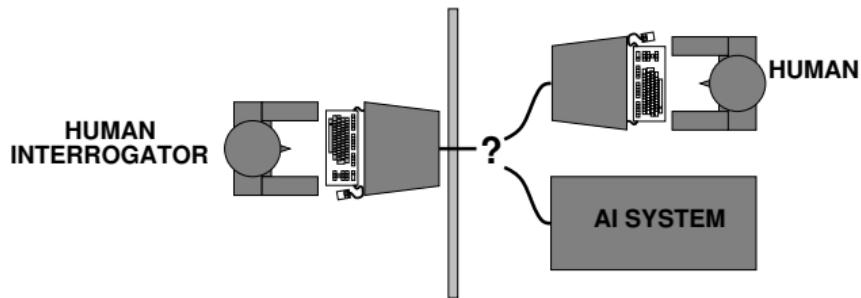
5 Aussagenlogik

6 Prädikatenlogik

7 Prolog

Turing-Test

Der Britische Mathematiker Alan Turing schlug 1950 in seinem Artikel „Computing Machinery and Intelligence“ einen Test zur Überprüfung intelligenten Verhaltens einer Maschine durch Vergleich mit einem Menschen vor:



- Eine Person befragt einen Menschen und ein KI-System, wobei der Tester jede beliebige Frage stellen kann.
- Der Tester kommuniziert nur indirekt über ein Textmedium. Dadurch soll vermieden werden, dass der Tester durch das äußere Erscheinen oder durch mechanische Eigenschaften wie eine synthetische Stimme beeinflusst wird.
- Der Tester soll allein aus den Antworten auf seine Fragen entscheiden, wer Mensch und wer Computer ist. Wenn er das nicht kann, dann ist die Maschine intelligent.

Anforderungen an das Computerprogramm:

- Sprachverstehen und Sprachgenerierung
- Repräsentation von Wissen
- Schlussfolgern
- Lernen

Der Artikel von Alan Turing enthält außerdem erste Gedanken zum Thema Lernen.

Übung 3. Implementieren Sie das Spiel Mastermind.

- schwarz: Ein Spielstein mit der richtigen Farbe wurde an der richtigen Stelle platziert.
- weiß: Ein Spielstein hat zwar die richtige Farbe, steht aber an der falschen Position.

[https://de.wikipedia.org/wiki/Mastermind_\(Spiel\)](https://de.wikipedia.org/wiki/Mastermind_(Spiel))



Anstelle verschieden farbiger Stecker verwenden wir Ziffern von 0 bis 5.

- Der Mensch denkt sich eine Kombination von vier Ziffern aus.
- Das Programm soll mit möglichst wenigen Versuchen diese Kombination ermitteln. In jedem Schritt gibt das Programm eine Kombination aus und wartet auf die Bewertung seines Versuchs durch den menschlichen Gegenspieler.
- Durch Analysieren der Bewertungen können nun Informationen gewonnen werden, die helfen, den nächsten Zug zu verbessern.

Beispiel: Der Mensch wählt die Kombination 0,1,2,3. Im folgenden Dialog macht der Computer jeweils einen Vorschlag, worauf der Mensch seine Bewertung abgibt.

1. Versuch: 3,3,3,1 --> Bewertung (s,w) ? 0,2
2. Versuch: 5,1,1,3 --> Bewertung (s,w) ? 2,0
3. Versuch: 2,1,4,3 --> Bewertung (s,w) ? 2,1
4. Versuch: 4,1,0,3 --> Bewertung (s,w) ? 2,1

Lösung: 0,1,2,3

Würden Sie ein solches Programm als intelligent bezeichnen?

Joseph Weizenbaum (1966) wird zum Gesellschaftskritiker wegen des Erfolgs seines Programms Eliza⁽⁵⁾:

- Oberflächliche Simulation eines Psychotherapeuten: erster Chatbot der Welt.
- Das Kommunikationsverhalten von Versuchspersonen gegenüber dem Programm entsprach demjenigen gegenüber einem menschlichen Gesprächspartner.
- Die Versuchspersonen waren zum Teil überzeugt, dass der Gesprächspartner ein tatsächliches Verständnis für ihre Probleme aufbrachte.
- Praktizierende Psychiater glaubten ernsthaft daran, mit dem Programm zu einer automatisierten Form der Psychotherapie gelangen zu können.

⁽⁵⁾<https://de.wikipedia.org/wiki/ELIZA>

- Ein Aussagesatz des Benutzers kann in einen Fragesatz umgewandelt werden, indem ein „Warum“ davor gestellt wird.
 - aus „Ich fühle mich unwohl in Gegenwart meiner Mutter.“ wird
 - „Warum fühlen Sie sich unwohl in Gegenwart Ihrer Mutter?“
- Eltern wissen, dass man durch Warum-Fragen schnell an die Wand gespielt wird. Daher: Reagiere auf Schlüsselwörter.
 - auf das Stichwort „Arbeit“ kann das Programm reagieren mit
 - „Haben Sie das Gefühl, Sie arbeiten zuviel?“ oder
 - „Kommt Ihre Familie zu kurz, wenn Sie viel arbeiten?“ oder
 - „Definieren Sie sich über Arbeit? Haben Sie keine Hobbies?“
- Zum Auflockern des Dialogs werden Phrasen eingestreut.
 - „Können Sie darauf bitte genauer eingehen?“
 - „Nehmen Sie kein Blatt vor den Mund.“
 - „Wie fühlen Sie sich jetzt?“
 - „Lassen Sie uns noch etwas bei diesem Thema bleiben.“
 - „Was denken Sie, sind die Gründe dafür?“
 - „Was könnte denn die Ursache von all dem sein?“

Anmerkungen:

- Das Erkennen von Schlüsselwörtern muss auch bei Rechtschreibfehlern korrekt funktionieren. Wir brauchen Fehlertoleranz im Dialog!
- Das Umstellen von Satzteilen ist je nach verwendeter Sprache unterschiedlich kompliziert und erfordert ein Erkennen der Satzstruktur, also der Grammatik.
- Deklination und Konjugation müssen berücksichtigt werden, um Schlüsselwörter zu erkennen: er wird sterben, sie ist gestorben, er starb, du stirbst usw.
- Wir müssen Synonyme erkennen und in die Antworten einbauen: umkommen, versterben, entschlafen, den Tod finden, von uns gehen, ums Leben kommen, dem Schöpfer gegenüber treten usw.

Anmerkungen:

- Um authentisch zu wirken, muss dem Programm die Umgangssprache bekannt sein: abkratzen, draufgehen, verrecken, den Löffel abgeben, über den Jordan gehen usw.
- Die Reaktion auf Schlüsselwörter kann von der Bedeutung eines Satzes abhängen:
 - „Mein Vater ist im *Krieg* gefallen“ ist sicherlich anders zu bewerten als „der *Krieg* ist der Vater aller Dinge“.
 - „Ich habe das Auto meines Vaters *gestohlen*“ unterscheidet sich deutlich von „ich *stehle* meiner Schwester die Show“.

→ Die Semantik ist wichtig und muss erkannt werden!

Um den Turing-Test wirklich zu bestehen, muss schon einiger Aufwand betrieben werden. Wird es jemals gelingen?

1 Übersicht

- Lernen durch Belohnung
- Planen

2 Geschichte und Anwendungen

- Turing-Test
- **neuronale Netze**
- Agenten
- Entscheidungsbäume
- Fallbasiertes Schließen
- Sequentielle Entscheidungsprobleme

3 Wissensrepräsentation

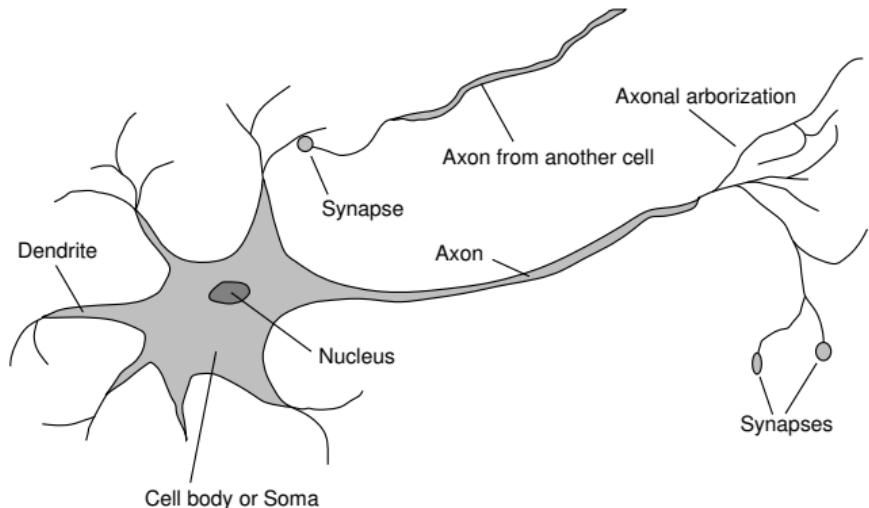
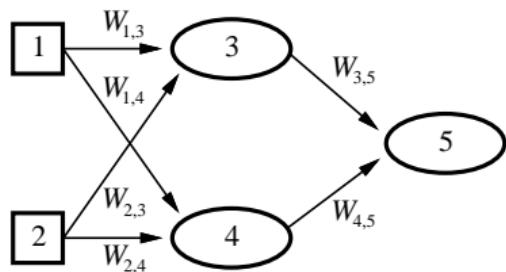
4 Zustandsraumsuche

5 Aussagenlogik

6 Prädikatenlogik

7 Prolog

Cullach/Pitt 1943: Integration dreier Quellen zum Vorschlag eines Netzes künstlicher Neuronen: Physiologie der Neuronen, Aussagenlogik und Theorie der Berechenbarkeit (von Alan Turing)⁽⁶⁾



⁽⁶⁾https://en.wikipedia.org/wiki/History_of_artificial_intelligence

Minsky/Edmonds 1951: Build the first artificial neural network (SNARC: Stochastic Neural Analog Reinforcement Calculator⁽⁷⁾) that simulated a rat finding its way through a maze.⁽⁸⁾

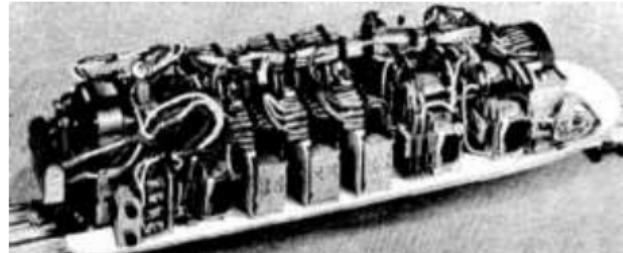
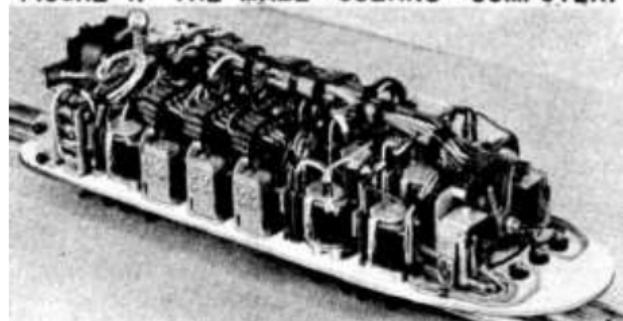


FIGURE 1. THE MAZE SOLVING COMPUTER.



(9)

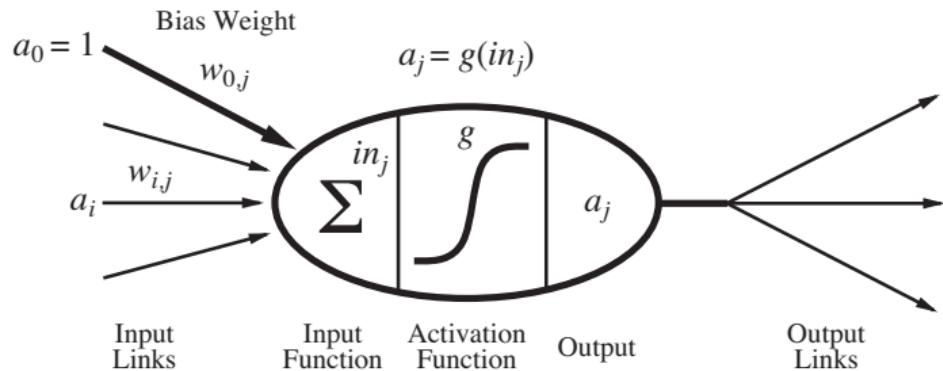
⁽⁷⁾https://en.wikipedia.org/wiki/Stochastic_Neural_Analog_Reinforcement_Calculator

⁽⁸⁾Toosi, Bottino, Saboury, Siegel, Rahmim. A Brief History of AI: How to Prevent Another Winter (A Critical Review) PET Clinics, 2021. <https://www.researchgate.net>

⁽⁹⁾<https://opendatascience.com/the-history-of-neural-networks-and-ai-part-i/>

Die von Minsky und Papert (1969) gezeigten theoretischen Grenzen von Perceptrons führen zu einem weitgehenden Ende der Forschungsförderung im Bereich neuronaler Netze.

Künstliches Neuron:

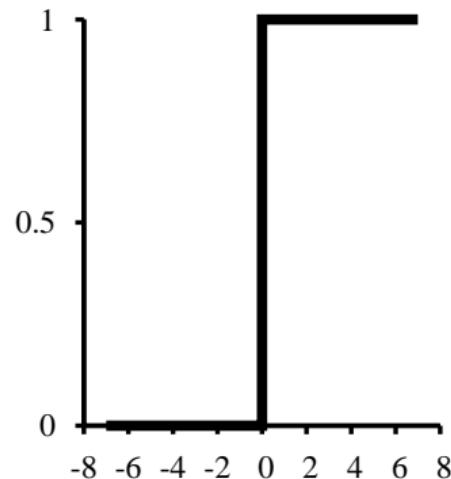


Die Input-Funktion berechnet die Summe der gewichteten Eingangssignale:

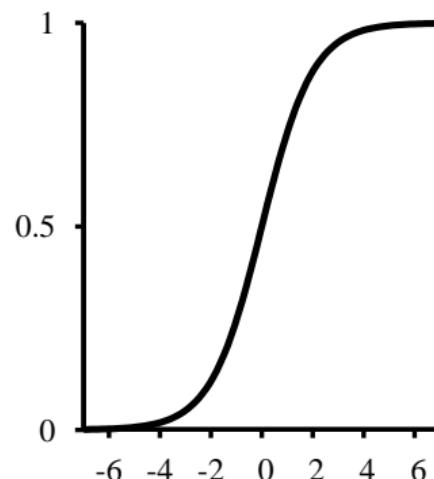
$$in_j = \sum_i a_i \cdot w_{ij}$$

Aktivierungsfunktionen bei neuronalen Netzen

Schwellwertfunktion:

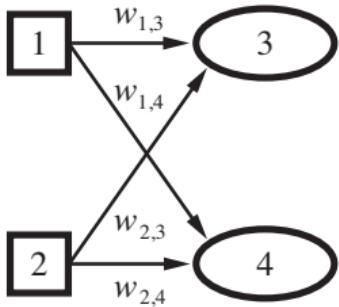


Logistische Funktion:

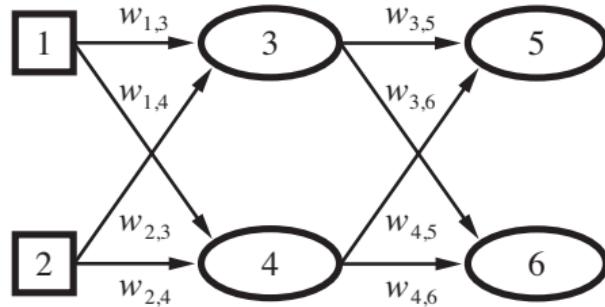


Häufig wird die logistische Funktion $\frac{1}{1+e^{-x}}$ oder der Tangens Hyperbolicus $\tanh(x)$ als Aktivierungsfunktion genutzt.

Vorwärts gerichtete neuronale Netze



(a)

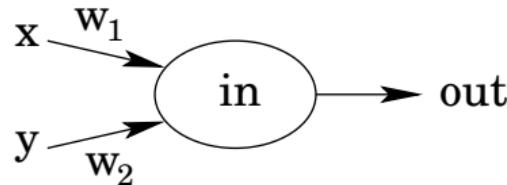


(b)

- **überwachtes Lernen:** Vergleiche Ist- mit Sollausgabe zu einer Eingabe. Schließe aus der Differenz auf die vorzunehmenden Änderungen der Gewichte.
 - Delta-Regel, Backpropagation
- **unüberwachtes Lernen:** Erfolgt ausschließlich durch Eingabe der zu lernenden Muster. Das Netz verändert sich entsprechend den Eingabemustern von selbst.
 - Hebb: Oft genutzte Pfade werden verstärkt.

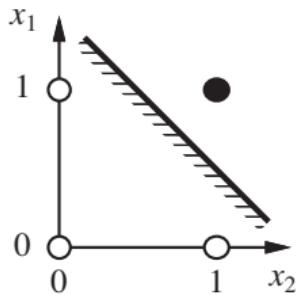
single layer perceptrons: artificial neurons connected by weights to a set of inputs

Linear separierbare Funktionen:

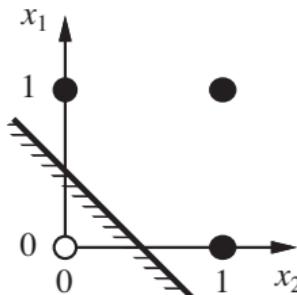


- Ein einzelnes Neuron mit zwei Eingängen x und y liefert $in = x \cdot w_1 + y \cdot w_2$.
- Die Gleichung ist linear in x und y , daher liegen alle Werte, die die Gleichung erfüllen, auf einer Geraden.
- Betrachten wir den einfachen Fall einer Schwellwertfunktion als Aktivierungsfunktion, dann gilt: Alle Werte auf einer der Seiten der Geraden produzieren Werte größer als der Schwellwert und aktivieren das Neuron.

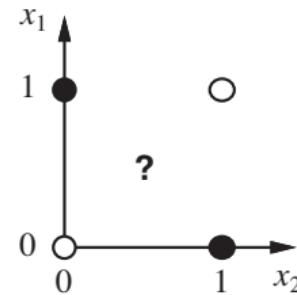
Minsky and Papert: a single layer perceptron cannot simulate a simple xor function.



(a) x_1 and x_2



(b) x_1 or x_2



(c) x_1 xor x_2

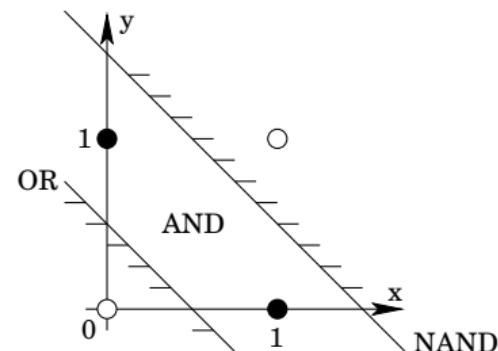
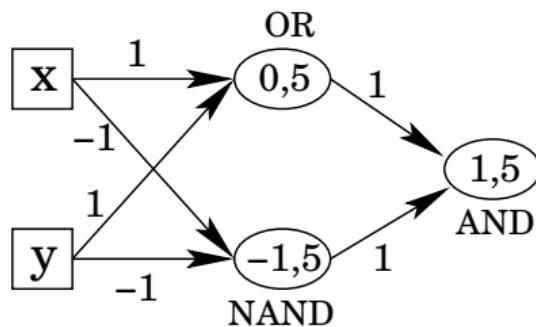
Exklusiv-Oder-Problem:

	w_1	w_2	Schwellwert
AND	1	1	1,5
OR	1	1	0,5
NAND	-1	-1	-1,5
XOR	?	?	?

- w_1 und w_2 beeinflussen die Steigung der Geraden,
- der Schwellwert beeinflusst die Position.

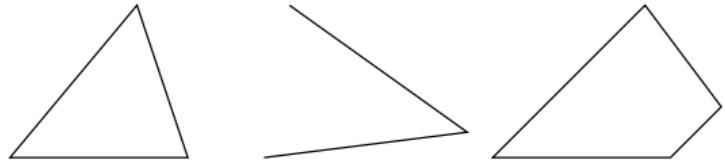
Fehler(?) von Minsky und Papert:

- Sie haben von der Leistung eines einstufigen Perceptrons mit einer trainierbaren Schicht unzulässiger Weise auf die Leistung eines mehrstufigen Perceptrons mit mehreren trainierbaren Schichten geschlossen.⁽¹⁰⁾
- Mehrstufige Perceptrons sind prinzipiell in der Lage, jede berechenbare Funktion zu realisieren.

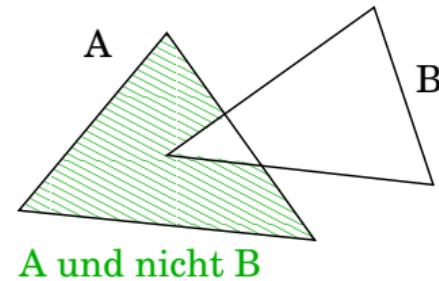


⁽¹⁰⁾ Dies ist laut wikipedia so nicht richtig: What the book does prove is that in three-layered feed-forward perceptrons, it is not possible to compute some predicates unless at least one of the neurons in the first layer of neurons is connected with a non-null weight to each and every input.

Einfache, zweischichtige Netze führen zu konvexen Regionen, die offen oder geschlossen sein können.



Mittels dreischichtigen Netzen können auch nicht-konvexe Regionen dargestellt werden.



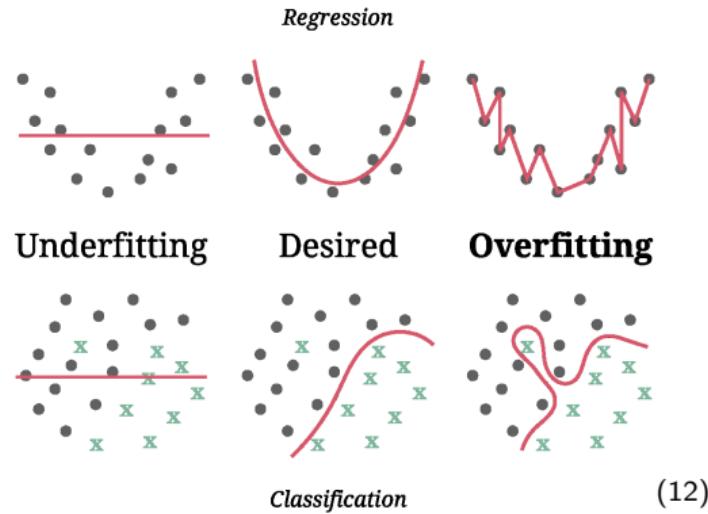
Typische Anwendungen: Klassifizierungen von Daten, Prognose für Börsenwerte oder Energieverbrauch, Steuerungen in der Robotik oder von Prothesen, Zeichenerkennung.

Universal Approximation Theorem for neural networks⁽¹¹⁾: Jede kontinuierliche Funktion eines beliebigen kompakten Teilraums von \mathbb{R}^n kann beliebig genau mit einem dreischichtigen Neuronalen Netz approximiert werden.

⁽¹¹⁾https://en.wikipedia.org/wiki/Universal_approximation_theorem

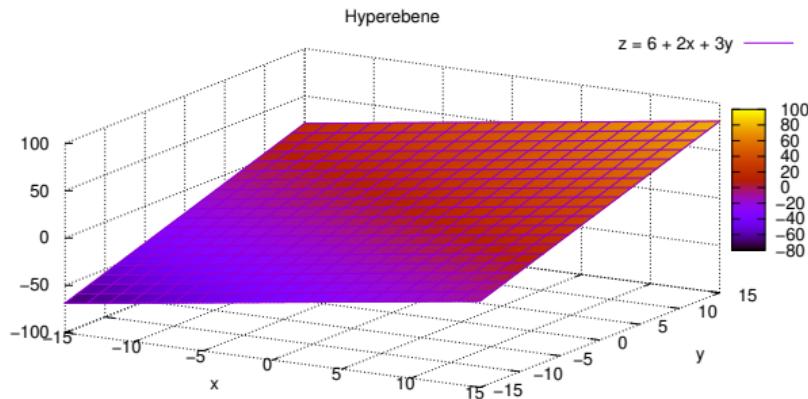
Problem:

- Wie viele Neuronen benötigen wir in den einzelnen Schichten?
- Wann ist das Netz ausreichend trainiert?
- Wie verhindert man eine zu starke Anpassung an die Trainingsdaten?



⁽¹²⁾https://therbootcamp.github.io/ML_2020Apr/_sessions/Prediction/Prediction.html#7

Linear separierbare Funktionen:



Ein Neuron mit 3 Eingängen liefert eine Ebene im 3D-Raum.

- $in = w_1 \cdot x + w_2 \cdot y + w_3 \cdot z \iff w_3 \cdot z = in - w_1 \cdot x - w_2 \cdot y$
- in der Grafik: $in = -12$, $w_3 = -2$, $w_1 = 4$, $w_2 = 6$

Allgemein liefert ein Neuron mit n Eingängen eine Hyperebene.

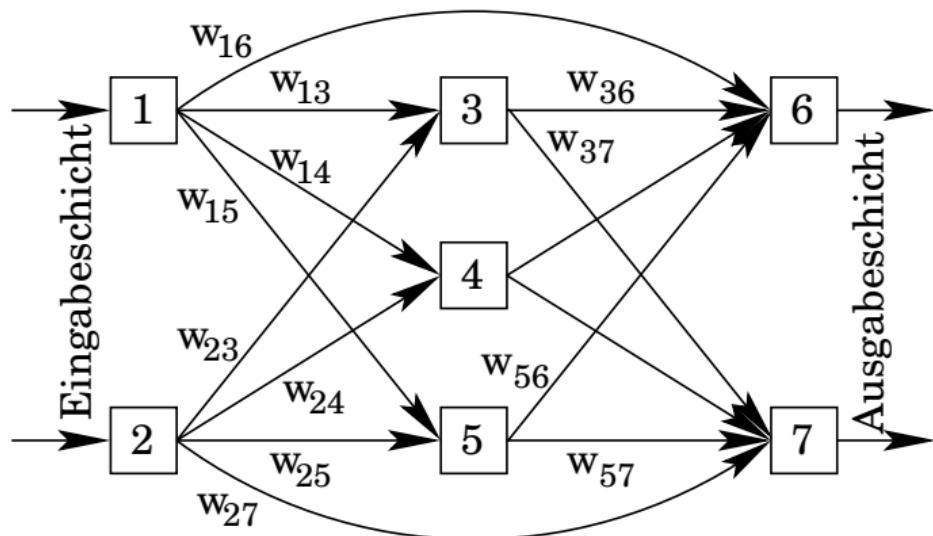
Das Buch von Rumelhart und McClelland *Parallel Distributed Processing*, 1986 verbreitete neue Erfolge mit dem wiederentdeckten Backpropagation-Algorithmus.

Der Backpropagation-Algorithmus wurde bereits 1969 von Bryson und Ho publiziert. Also im gleichen Jahr, in dem das kritische Buch von Minsky und Papert erschienen ist.

Backpropagation: Gradientenabstiegsverfahren zur Minimierung des Fehlers, also der Abweichung zwischen Ausgabe (Ist-Wert) und erwarteter Ausgabe (Soll-Wert).

- vorwärts gerichtete Netzwerke
- Matrix w speichert Gewichte der Kanten: w_{ij} ist das Gewicht der Kante von Neuron i zu Neuron j
- Aktivierungsfunktion: $\frac{1}{1+e^{-x}}$ ist überall differenzierbar

- out_i : Ausgabe des Neurons i .
- $in_j = \sum_i out_i \cdot w_{ij}$
- die Aktivierungsfunktion liefert: $out_j = \frac{1}{1+e^{-in_j}}$



Oft definiert man den Fehler des neuronalen Netzes

$$E = \frac{1}{2} \sum_j (t_j - \text{out}_j)^2$$

als Quadrat der Abweichung zwischen erwarteter Ausgabe und realer Ausgabe, damit sich negative und positive Abweichungen nicht aufheben.

Der Fehler wird minimiert, indem jedes Gewicht um einen durch die Lernrate η festgelegten Bruchteil des negativen Gradienten der Fehlerfunktion geändert wird:

$$\Delta w_{ij} = -\eta \cdot \frac{\partial E}{\partial w_{ij}}$$

Die Lernrate η steuert den Grad der Gewichtsänderung und das negative Vorzeichen bewirkt eine Veränderung entgegen dem Kurvenanstieg in Richtung eines Tals der Fehlerkurve.

Die Kettenregel liefert:

$$\Delta w_{ij} = -\eta \cdot \frac{\partial E}{\partial w_{ij}} = -\eta \cdot \frac{\partial E}{\partial in_j} \cdot \frac{\partial in_j}{\partial w_{ij}}$$

- $\frac{\partial in_j}{\partial w_{ij}} = \frac{\partial}{\partial w_{ij}} \sum_k out_k \cdot w_{kj} = out_i$
- Wir definieren als Fehlersignal: $\delta_j = -\frac{\partial E}{\partial in_j}$

Damit erhalten wir:

$$\Delta w_{ij} = \eta \cdot \delta_j \cdot out_i$$

Gewichtsänderung:

$$w_{ij}^{neu} := w_{ij}^{alt} + \Delta w_{ij}$$

Wir müssen jetzt nur noch das Fehlersignal $\delta_j = -\frac{\partial E}{\partial \text{in}_j}$ bestimmen.

Auch hier können wir wieder die Kettenregel anwenden:

$$\delta_j = -\frac{\partial E}{\partial \text{out}_j} \frac{\partial \text{out}_j}{\partial \text{in}_j}$$

Der zweite Faktor entspricht der ersten Ableitung der Aktivierungsfunktion:

$$\begin{aligned}\frac{\partial \text{out}_j}{\partial \text{in}_j} &= \frac{\partial}{\partial \text{in}_j} \frac{1}{1 + e^{-\text{in}_j}} = -\frac{-e^{-\text{in}_j}}{(1 + e^{-\text{in}_j})^2} = \frac{e^{-\text{in}_j}}{(1 + e^{-\text{in}_j})^2} \\ &= \frac{1}{1 + e^{-\text{in}_j}} \cdot \left(\frac{e^{-\text{in}_j}}{1 + e^{-\text{in}_j}} \right) \\ &= \text{out}_j \cdot \left(\frac{1 + e^{-\text{in}_j} - 1}{1 + e^{-\text{in}_j}} \right) \\ &= \text{out}_j \cdot (1 - \text{out}_j)\end{aligned}$$

Für die Berechnung des ersten Faktors $-\frac{\partial E}{\partial out_j}$ benötigen wir eine Fallunterscheidung:

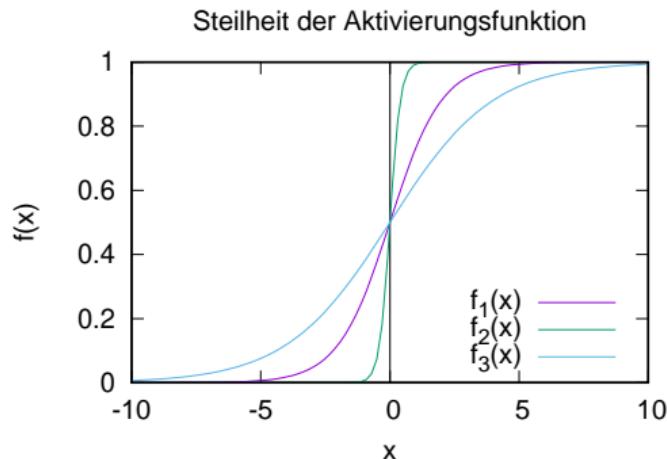
- Für ein **Neuron j der Ausgabeschicht**, dessen Fehler sich nicht auf andere Knoten auswirkt, gilt:

$$-\frac{\partial E}{\partial out_j} = -\frac{\partial}{\partial out_j} \left(\frac{1}{2} \sum_k (t_k - out_k)^2 \right) = (t_j - out_j)$$

- Für ein **Neuron j aus einer Zwischenschicht** ist t_j nicht bekannt. Aber die verallgemeinerte Kettenregel liefert:

$$\begin{aligned} -\frac{\partial E}{\partial out_j} &= -\sum_k \frac{\partial E}{\partial in_k} \frac{\partial in_k}{\partial out_j} \\ &= \sum_k \left(\delta_k \frac{\partial}{\partial out_j} \sum_l out_l \cdot w_{lk} \right) = \sum_k \delta_k w_{jk} \end{aligned}$$

Die Steilheit der Kurve⁽¹³⁾ beim Übergang von 0 auf 1 kann durch einen zusätzlichen Faktor im Exponenten gesteuert werden:



$$f_1(x) = \frac{1}{1 + e^{-x}}$$

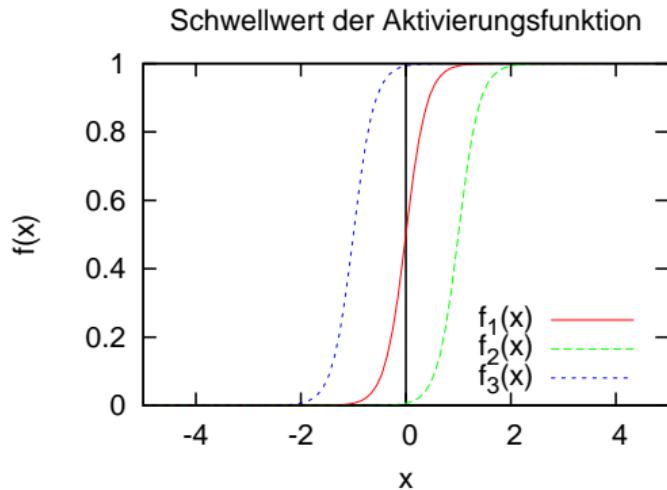
$$f_2(x) = \frac{1}{1 + e^{-5x}}$$

$$f_3(x) = \frac{1}{1 + e^{-0.5x}}$$

Durch einen großen Faktor kann also eine Schwellwertfunktion nachgebildet werden.

⁽¹³⁾Die Überlegungen zum XOR-Problem lassen sich damit übertragen und die Netze mittels Backpropagation trainieren. Mit einer echten Schwellwertfunktion funktioniert Backpropagation nicht, da die Funktion an der Stelle $x = 0$ nicht differenzierbar ist (der Gradient wäre unendlich) und an allen anderen Stellen ist der Gradient gleich 0, es ergäbe sich also keine Änderung der Gewichte.

Soll der Schwellenwert von 0 auf einen anderen Wert verschoben werden, wird noch ein additiver Term im Exponenten eingefügt:



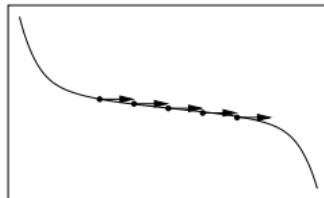
$$f_1(x) = \frac{1}{1 + e^{-5x}}$$

$$f_2(x) = \frac{1}{1 + e^{-5(x-1)}}$$

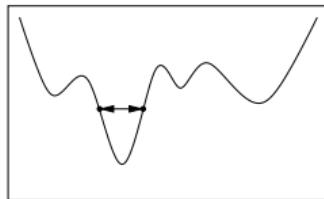
$$f_3(x) = \frac{1}{1 + e^{-5(x+1)}}$$

Bias: Festes Eingabesignal 1 über eine Kante mit Gewicht θ mit einem Neuron verbinden. So wird der Schwellenwert zu einem weiteren Gewicht, und wir müssen beim Lernen nur Gewichte optimieren. Das Bias ermöglicht es dem Modell, die Aktivierungsfunktion zu verschieben.

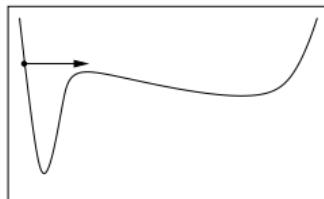
Eventuelle Schwierigkeiten beim Lernen:



Ist die Kurve sehr flach, dann ist der Anstieg betragsmäßig sehr klein, woraus eine geringe Gewichtsänderung resultiert. Der Trainingsprozess nimmt viel Zeit in Anspruch.



Oszillation in sehr steilen Schluchten: Durch den großen Anstieg erfolgt eine große Gewichtsänderung und es wird von einer Wand zur anderen gesprungen.



Durch eine steile Wand führt eine große Gewichtsänderung dazu, dass das tiefe Tal übersprungen wird und nur noch ein lokales Optimum gefunden wird.

Lernrate:

- klein → langsame Änderung der Gewichte, viele Iterationsschritte notwendig
- groß → schnelle Änderung der Gewichte, evtl. Oszillation um idealen Gewichtsvektor, evtl. wird Minimum nicht gefunden

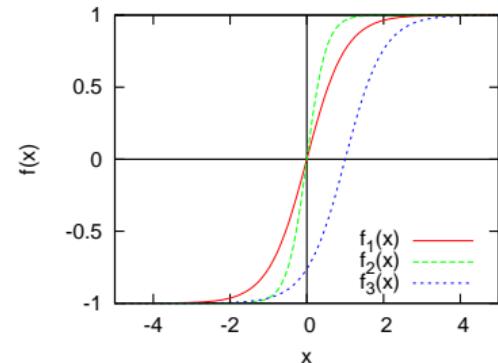
→ monoton fallende Folge über alle Lernschritte (Problem: Bestimmung der Parameter für diese Folge?)

Damit auch inaktive Zustände eine Gewichtsänderung beim Training bewirken, verwendet man den Wertebereich $[-1, +1]$:

$$f_1(x) = \tanh(x)$$

$$f_2(x) = \tanh(2x) \quad \frac{d \tanh(x)}{dx} = \frac{1}{\cosh^2(x)}$$

$$f_3(x) = \tanh(x - 1)$$



Beispiel: NETtalk⁽¹⁴⁾ lernte die Aussprache von englischem Text.

- Extrem schwierig für symbolbasierten Ansatz, da die englische Aussprache äußerst unregelmäßig ist.
- vorher: komplizierte Programme liefern schlechte Resultate.
- Aussprache eines Buchstabens ist kontextabhängig, daher wird jeweils ein Textfenster von sieben Zeichen untersucht.
- Während der Text dieses Textfenster durchläuft, gibt NETtalk die Aussprache jeweils des mittleren Buchstabens aus.
- Eigenschaften spiegeln Wesen menschlichen Lernens wider:
 - Je mehr Wörter das Netz aussprechen lernt, desto besser ist es in der Lage, neue Wörter korrekt auszusprechen.
 - Das Netz ist fehlerresistent: Werden einige Gewichte eines gut trainierten Netzes zufällig geändert, bleibt die Aussprache gut.
 - Weniger Neuronen in der verborgenen Schicht als in der Eingabeschicht → es findet irgendeine Art von Abstraktion statt

⁽¹⁴⁾ Sejnowski, Rosenberg: Parallel networks that learn to pronounce english text. Complex Systems, 1987.

Counterpropagation:

- Biologisches Vorbild: Man vermutet, dass im Gehirn spezialisierte Module hintereinander geschaltet sind, um eine gewünschte Berechnung auszuführen.
- Hier: Eingabe-, Kohonen- und Grossberg-Schicht.
- vollständige Vernetzung der Schichten: Jedes Neuron der Eingabeschicht ist mit jedem Neuron der Kohonenschicht verbunden. analog: Kohonen- und Grossberg-Schicht.
- normalisierte Eingabevektoren:

$$x_i^{\text{normalisiert}} := \frac{x_i}{\sqrt{x_1^2 + x_2^2 + \dots + x_n^2}}$$

→ Der normalisierte Vektor zeigt in die gleiche Richtung wie der ursprüngliche Vektor, hat aber Einheitslänge.

zugrunde liegende Idee:

- zweidimensionaler Fall: Das Skalarprodukt zwischen dem normalisierten Gewichts- und Eingabevektor ist gleich dem Cosinus des Winkels zwischen Eingabe- und Gewichtsvektor.

$$\begin{aligned}\vec{a} \cdot \vec{b} &= |\vec{a}| \cdot |\vec{b}| \cdot \cos(\angle(\vec{a}, \vec{b})) \\ \vec{a} \cdot \vec{b} &= a_x \cdot b_x + a_y \cdot b_y\end{aligned}$$

Mit Hilfe dieser Formeln können wir den Winkel zwischen den Vektoren bestimmen:

$$\cos(\angle(\vec{a}, \vec{b})) = \frac{a_x \cdot b_x + a_y \cdot b_y}{|\vec{a}| \cdot |\vec{b}|}$$

- Je kleiner der Winkel zwischen Gewichts- und Eingabevektor ist, also je dichter die beiden Vektoren beieinander liegen, umso größer ist der Wert der Aktivierungsfunktion.

zugrunde liegende Idee: (Fortsetzung)

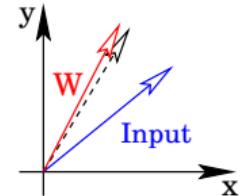
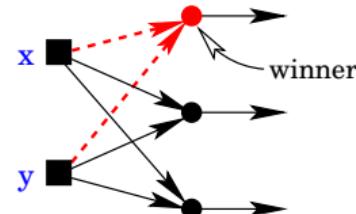
- Das Neuron der Kohonenschicht, dessen Gewichtsvektor die größte Ähnlichkeit zum Eingabevektor zeigt, hat die größte Aktivität.
- The winner takes it all: Legt man einen Eingabevektor an die Kohonenschicht an, so wird die Ausgabe des Neurons auf 1 gesetzt, dessen Gewichtsvektor die größte Ähnlichkeit mit dem Eingabevektor hat.

⇒ Betrachtet man jeden einzelnen Gewichtsvektor als Klasse oder Kategorie, so findet eine Klassifizierung des angelegten Eingabevektors in die für ihn am besten passende Kategorie statt.

Eingabeschicht: Verteilt die Eingangssignale an alle Neuronen der nächsten Schicht, der Kohonen-Schicht.

Kohonen-Schicht:

- Lege Eingabe(vektor) an und berechne für alle Neuronen den Wert der Aktivierungsfunktion.
- The winner takes it all: Die Ausgabe des Neurons mit größtem Eingangssignal wird auf 1 gesetzt, alle anderen Ausgaben werden auf 0 gesetzt.
- Die Gewichte des *Gewinner*-Neurons werden korrigiert: Das *Gewinner*-Neuron hat die größte Ähnlichkeit mit dem Eingabevektor; die Gewichtsänderungen machen die Vektoren noch *ähnlicher*.



Training der Kohonen-Schicht mittels Delta-Regel: Sei \vec{w} der Gewichtsvektor des *Gewinner*-Neurons, α die Lernrate und \vec{x} der Eingabevektor.

$$\vec{w}^{new} = \vec{w}^{old} + \alpha \cdot (\vec{x} - \vec{w}^{old})$$

Anmerkungen zur Kohonen-Schicht:

- Gewichte werden mit Zufallswerten initialisiert und beim Einsatz der Lernmethode normalisiert.
- Das Kohonen-Netz muss stabil sein, bevor das Grossberg-Netz trainiert werden kann.

Variationen der Kohonen-Schicht:

- „Bewusstseinsparameter“ einführen und in jeder Iteration aktualisieren: Das verhindert, dass einzelne Neuronen zu oft gewinnen. → Alle Knoten tragen zur Repräsentation des Musterraums bei.
- Wähle anstatt eines Gewinners eine Menge von ähnlichsten Knoten und ändere deren Gewichte differenziell.
- Teile den Nachbarknoten des Gewinners eine differenzielle Belohnung zu.

Grossberg-Schicht:

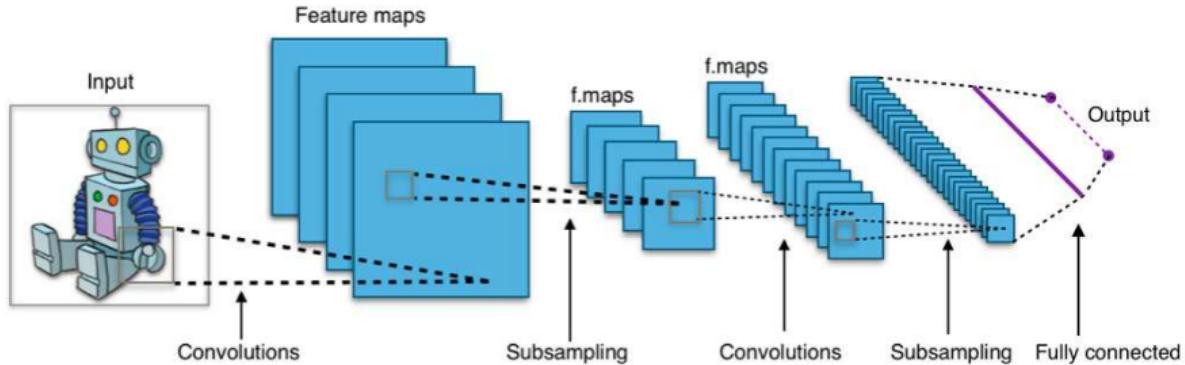
- Die einzige Aufgabe der Grossberg-Schicht ist es, die zuvor gelernten Klassen zu benennen, also die gewünschte Ausgabe zu erzeugen.
- Nach dem Anlegen eines Eingabevektors wird das *Gewinner*-Neuron i der Kohonenschicht bestimmt.
- Anschließend wird das Gewicht v_{ij} zu einem Neuron j der Grossberg-Schicht so geändert, dass der Unterschied zwischen Ist-Ausgabe und Soll-Ausgabe reduziert wird.

Training der Grossberg-Schicht mittels Delta-Regel: Sei i das *Gewinner*-Neuron.

$$v_{ij}^{new} = v_{ij}^{old} + \beta \cdot (t_j - v_{ij}^{old})$$

Oft wird $\beta = 0.1$ gesetzt und im Laufe des Trainings, also mit zunehmendem Lernfortschritt, langsam reduziert.

Convolutional Neural Networks sind eine Sonderform von mehrschichtigen Perzeptrons. Daher sind beide Modelle prinzipiell identisch in ihrer Ausdrucksstärke. Bild: wikipedia



Vier Annahmen verringern den Berechnungsaufwand des Netzes und lassen tiefere Netzwerke zu.

- geteilte Gewichte im Convolutional Layer
- Pooling: verwerfe Großteil der Aktivität eines Layers
- ReLu: extrem einfach zu berechnende Aktivierungsfunktion $f(x) = \max\{0, x\}$
- Dropout (entferne zufällige Neuronen) verhindert Overfitting

Convolutional Layer

Der mittels diskreter Faltung ermittelte Input eines jeden Neurons wird von einer Aktivierungsfunktion, oft Rectified Linear Unit (ReLU) in den Output verwandelt.

Intuitiv: Bewege schrittweise eine kleine Faltungsmatrix über die Eingabe.

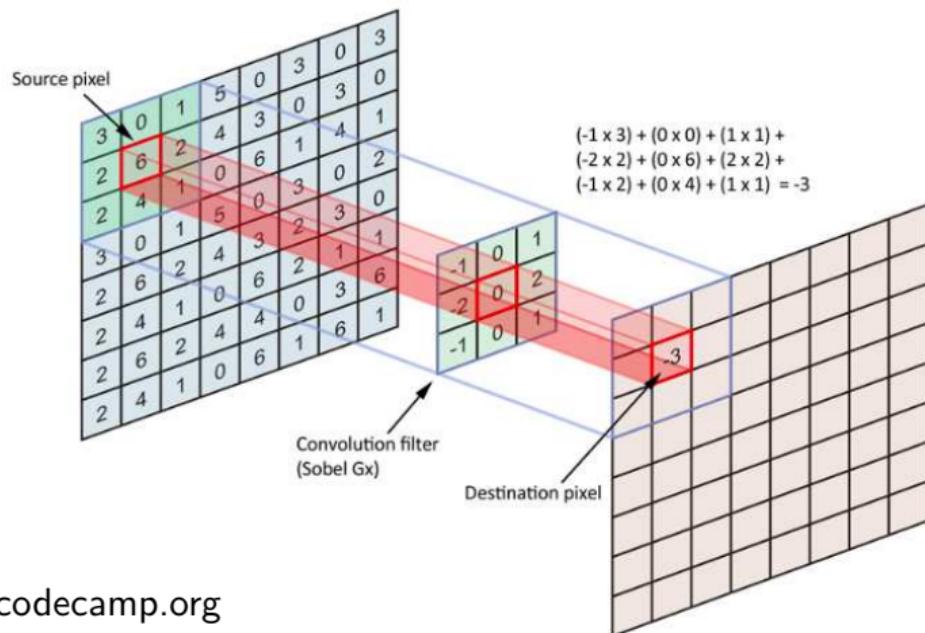
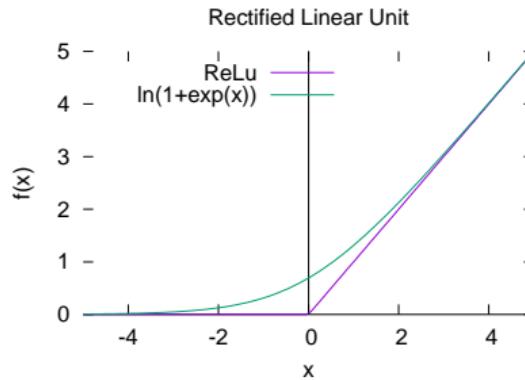


Bild: www.freecodecamp.org

Convolutional Layer

Verschiedene Faltungsmatrizen ergeben unterschiedliche Feature-Maps. Die Gewichte einer Matrix werden mittels Backpropagation trainiert.

- Gewichte aller Neuronen eines Convolutional Layers sind identisch
→ schnelleres Training als bei Perzeptrons
- Backpropagation verlangt die Berechnung der Gradienten
→ nutze differenzierbare Approximation wie $f(x) = \ln(1 + e^x)$



Berechnung wäre viel zu aufwändig → wähle an der einzigen nicht differenzierbaren Stelle als Steigung Null

Pooling Layer

Im Pooling-Layer werden überflüssige Informationen verworfen.

Zur Objekterkennung in Bildern etwa, ist die exakte Position einer Kante im Bild von vernachlässigbarem Interesse - die ungefähre Lokalisierung eines Features ist oft hinreichend.

Es gibt verschiedene Arten des Poolings. Mit Abstand am stärksten verbreitet ist das Max-Pooling: Wähle maximale Aktivität aus jedem 2×2 Quadrat.

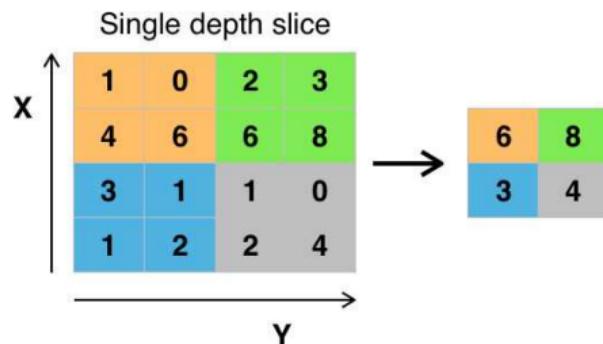


Bild: https://de.wikipedia.org/wiki/Convolutional_Neural_Network

Information kann nicht generell weitergegeben werden, ohne dadurch weniger zu werden. Das Ausmaß des Verlustes hängt von den physikalischen Randbedingungen ab. Gemäß Shannon kann bei einer Übertragung nicht mehr Information aus einem Kanal entnommen werden als auf der Senderseite hineingegeben wird.⁽¹⁵⁾

Folgerung: Je tiefer die Netze, umso größer der Informationsverlust. Warum sollte es also erstrebenswert sein, tiefe neuronale Netze zu nutzen?

Die Interpretierbarkeit der Parameter und Erklärbarkeit des Zustandekommens der Ergebnisse ist hier nur noch eingeschränkt möglich und erfordert den Einsatz spezieller Techniken, die unter Explainable Artificial Intelligence zusammengefasst werden.⁽¹⁶⁾

neuer Ansatz von Naftali Tishby: The idea is that a network rids noisy input data of extraneous details as if by squeezing the information through a bottleneck, retaining only the features most relevant to general concepts.⁽¹⁷⁾

⁽¹⁵⁾<https://de.wikipedia.org/wiki/Information>

⁽¹⁶⁾https://de.wikipedia.org/wiki/Deep_Learning

⁽¹⁷⁾<https://www.quantamagazine.org/>

Aufgrund des universellen Approximationstheorems wissen wir, dass

- eine versteckte Schicht theoretisch ausreichend ist und
- keine Notwendigkeit für tiefe neuronale Netze besteht.

Aber das Theorem macht keine Aussage über die voraussichtliche Anzahl an Neuronen in der versteckten Schicht!

→ Abhängig von der zu approximierenden Funktion kann eine enorm große Anzahl an Neuronen notwendig sein.⁽¹⁸⁾⁽¹⁹⁾

Durch das Hinzufügen weiterer versteckter Schichten kann die gleiche Approximationsgüte eventuell mit weniger Neuronen erzielt werden.

⁽¹⁸⁾M. Telgarsky. Benefits of depth in neural networks. Journal of Machine Learning Research, 2016. <https://arxiv.org/pdf/1602.04485>

⁽¹⁹⁾R. Eldan and O. Shamir. The power of depth for feedforward neural networks. Journal of Machine Learning Research, 2016. <https://arxiv.org/pdf/1512.03965>

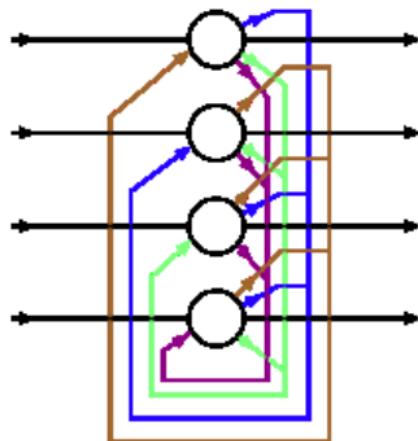
Hopfield-Netze

Hopfield-Netze⁽²⁰⁾ sind Netze mit Rückkopplung, die nur aus einer Schicht bestehen, die gleichzeitig als Ein- und Ausgabeschicht fungiert.

Jedes der binären McCulloch-Pitts-Neuronen ist mit jedem, ausgenommen sich selbst, verbunden⁽²¹⁾. Die Neuronen können die Werte 0 und 1 annehmen⁽²²⁾.

In Hopfield-Netzwerken sind die synaptischen Gewichte symmetrisch, d.h. es gilt $w_{i,j} = w_{j,i}$ für alle i und j .

Dies ist zwar biologisch nicht sinnvoll, erlaubt aber das Aufstellen einer Energiefunktion und die Analyse der Netzwerke mit Methoden der statistischen Mechanik.



⁽²⁰⁾<https://de.wikipedia.org/wiki/Hopfield-Netz>

⁽²¹⁾Cohen, Grossberg: Absolute stability of global pattern formation and parallel memory storage by competitive neural networks. IEEE Transaction on Systems, Man and Cybernetics 13, 815-826, 1983.

⁽²²⁾Manchmal auch die Werte -1 und 1 oder auch kontinuierliche Werte dazwischen.

Für ein einzelnes Neuron j und dessen Schwellenwert θ_j gilt:

$$net_j = \sum_{i \neq j} w_{ij} \cdot out_i + in_j \quad \text{und} \quad out_j = \begin{cases} 1 & \text{wenn } net_j > \theta_j, \\ 0 & \text{sonst} \end{cases}$$

Die Stabilität eines solchen Netzwerks kann mittels einer Liapunov-Funktion gezeigt werden. Der Wert einer solchen Funktion fällt jedesmal, wenn sich der Zustand des Netzwerks ändert.

$$E = -\frac{1}{2} \sum_{i \neq j} w_{ij} \cdot out_i \cdot out_j + \sum_i \theta_i \cdot out_i$$

Nur bei den stabilen Mustern bleibt auch die Energie gleich, diese stellen also lokale Minima der Energielandschaft dar.

Hopfield-Netze: Assoziativer Speicher⁽²³⁾

Die Muster werden als binäre Vektoren in den Gewichten des Netzes gespeichert.

$$w_{ij} = \sum_{d=1}^m (out_{i,d} \cdot out_{j,d})$$

Dabei bezeichnet m die Anzahl der zu speichernden Muster, d den jeweiligen Vektor des Musters und $out_{i,d}$ die gewünschte i -te Komponente des entsprechenden Vektors.

Ein verrauschtes oder unvollständiges Bild wird als Eingabevektor angelegt. Dann wird der Eingabevektor entfernt und die Neuronen werden asynchron mit folgender Regel aktualisiert.

$$out_i = \begin{cases} 1 & \text{wenn } \sum_j w_{ij} \cdot out_j > \theta_i, \\ 0 & \text{sonst} \end{cases}$$

Dabei ist out_i der Zustand des zu aktualisierenden Neurons und θ_i ein Schwellenwert.

⁽²³⁾Das menschliche Gedächtnis arbeitet assoziativ, d.h. ein Teil einer Erinnerung kann eine größere, damit verbundene Erinnerung hervorrufen. So kann beispielsweise das Hören von nur wenigen Takten Musik ein komplettes sensorisches Erlebnis, einschließlich Szenen, Geräuschen und Gerüchen, in Erinnerung rufen. aus Philip D. Wasserman. Neural Computing: Theory and Practice.

Um das Problem für n Städte zu lösen, nutzen wir die Energiefunktion $E = E_1 + E_2$ und n^2 viele Neuronen. Dabei beschreibt $out_{x,i} = 1$, dass Knoten x der i -te Knoten auf der Tour ist.

Der erste Teil E_1 der Energiefunktion beschreibt die Randbedingungen des Problems: Jeder Knoten muss genau einmal auf der Rundreise besucht werden.

$$\begin{aligned} E_1 = & \frac{A}{2} \sum_x \sum_i \sum_{j \neq i} out_{x,i} \cdot out_{x,j} + \frac{B}{2} \sum_i \sum_x \sum_{y \neq x} out_{x,i} \cdot out_{y,i} \\ & + \frac{C}{2} \left(\left(\sum_x \sum_i out_{x,i} \right) - n \right)^2 \end{aligned}$$

Wann werden die jeweiligen Teile minimal?

- Jeder Knoten x steht maximal an einer einzigen Position in der Tour.
- An jeder Position i der Tour steht maximal ein einziger Knoten.
- Genau n Knoten kommen in der Tour vor. (nicht alle Variablen sind gleich 0)

Der zweite Teil der Energiefunktion beschreibt die Optimalität, also die minimale Länge der Rundreise:

$$E_2 = \frac{1}{2D} \sum_x \sum_{y \neq x} \sum_i d_{x,y} \cdot out_{x,i} \cdot (out_{y,i+1} + out_{y,i-1})$$

Dabei ist $d_{x,y}$ die Distanz zwischen Knoten x und y . Wir gehen hier davon aus, dass die Distanzen symmetrisch sind, also $d_{x,y} = d_{y,x}$ gilt.

- Ausreichend große Werte für A , B und C stellen sicher, dass niedrige Energiewerte zulässige Lösungen repräsentieren.
- Ein großer Wert für D stellt sicher, dass eine kurze Rundreise gefunden wird.

Die Gewichte werden wie folgt bestimmt:

$$w_{xi,yj} = -A \cdot \delta_{xy} \cdot (1 - \delta_{ij}) - B \cdot \delta_{ij} \cdot (1 - \delta_{xy}) - C - D \cdot d_{xy} \cdot (\delta_{j,i+1} + \delta_{j,i-1})$$

wobei $\delta_{ij} \in \{0, 1\}$ mit $\delta_{ij} = 1$, wenn $i = j$. (Kronecker-Delta)

Anmerkungen:

- Die Wahl der Koeffizienten ist kritisch. Andere Autoren schlagen andere Werte vor, bspw. Van den Bout and Miller. A traveling salesman objective function that works. Proceedings of the IEEE International Conference on Neural Networks, volume 2, pp. 299-303, 1988.
- Es gibt weitere, rückgekoppelte Netze wie die Elman-Netze⁽²⁴⁾. Solche können zeitliche Abhängigkeiten von Eingaben verarbeiten.
- Um „Long Short-Term Memory“ (LSTM) zu implementieren, nutzte man viele Jahre rückgekoppelte Netzwerke⁽²⁵⁾. LSTM eignet sich für die Klassifizierung, Verarbeitung und Vorhersage von Daten auf der Grundlage von Zeitreihen, z.B. in den Bereichen Handschriften- und Spracherkennung oder maschinelle Übersetzung.
- Heute nutzt man anstelle von LSTM eine Transformer-Architektur⁽²⁶⁾, die ohne rückgekoppelte Netze auskommen. Wird bei Large-Language-Model eingesetzt.

⁽²⁴⁾<https://de.wikipedia.org/wiki/Elman-Netz>

⁽²⁵⁾https://en.wikipedia.org/wiki/Long_short-term_memory

⁽²⁶⁾[https://en.wikipedia.org/wiki/Transformer_\(deep_learning_architecture\)](https://en.wikipedia.org/wiki/Transformer_(deep_learning_architecture))

TSP ist NP-vollständig. Wenn ein Hopfield-Netz das TSP lösen kann, ist das dann nicht ein Widerspruch?

- Das Verhalten der Hopfield-Netze hängt von der Update-Reihenfolge ab, es wird nicht immer ein globales Optimum gefunden.
- Bei n Neuronen, wird die Konvergenz⁽²⁷⁾ nach höchstens $n \cdot 2^n$ vielen Schritten erreicht, die Laufzeit ist also exponentiell.

⁽²⁷⁾<https://de.wikipedia.org/wiki/Hopfield-Netz#Konvergenzsatz>
Wissensbasierte Systeme

1 Übersicht

- Lernen durch Belohnung
- Planen

2 Geschichte und Anwendungen

- Turing-Test
- neuronale Netze
- **Agenten**
- Entscheidungsbäume
- Fallbasiertes Schließen
- Sequentielle Entscheidungsprobleme

3 Wissensrepräsentation

4 Zustandsraumsuche

5 Aussagenlogik

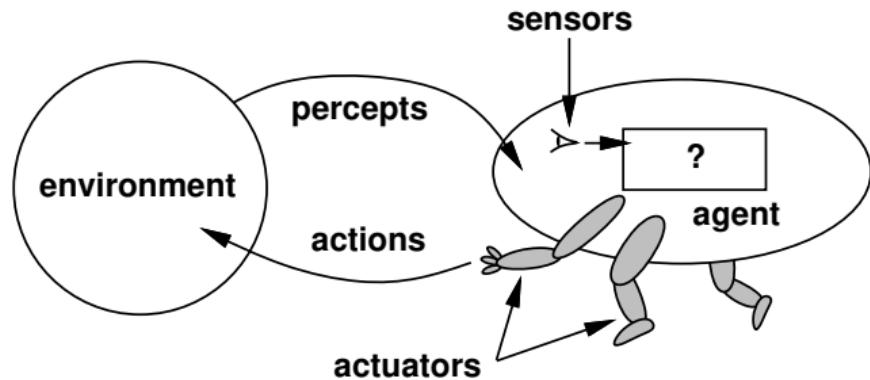
6 Prädikatenlogik

7 Prolog

Viele Forscher aus den Anwendungsbereichen Robotik, Entwurf von Spielen oder dem Internet haben eine zentrale Wissensbasis oder allgemein gültige Inferenzschemata seit 1995 in Frage gestellt.

Problemlösungsverfahren werden als verteilte Agenten entworfen, die kontextbezogen, autonom und flexibel sind.

Agenten nehmen Umgebung mittels Sensoren wahr und reagieren darauf autonom und rational mittels Effektoren.



Analogie zu agentenbasierten Systemen: Brotbedarf in Städten⁽²⁸⁾

- Es wäre extrem schwierig, ein zentrales Planungsmodul zu entwickeln, dass eine Großstadt erfolgreich mit der vielfältigen Auswahl an täglich frischem Brot versorgen könnte.
- Aber die locker koordinierten Bemühungen der vielen Bäcker, Lastwagenfahrer, Lieferanten der Rohmaterialien sowie der Einzelhändler lösen das Problem sehr gut:
 - Es gibt keinen zentralen Plan.
 - Kein Bäcker hat mehr als ein begrenztes Wissen über den Brotbedarf der Stadt.
 - Jeder Bäcker versucht, sein eigenes Geschäft zu optimieren.
 - Die Lösung des globalen Problems ergibt sich aus den kollektiven Aktivitäten der unabhängigen lokalen Agenten.
- Leider neigen solche Ansätze zur Überproduktion.

⁽²⁸⁾ Luger: Künstliche Intelligenz. Pearson Studium.

Software-Agenten:

- Die Problemlösungsaufgabe wird in ihre verschiedenen Bestandteile aufgeschlüsselt.
- Die Teilaufgaben werden kaum oder gar nicht zentral koordiniert.
- Intelligenz ist in einen Kontext eingebettet. → Ein einzelner Problemlöser kann sich einer bestimmten Aufgabe zuwenden, ohne über Informationen zum Status der Lösung in der übergeordneten Problemdomäne verfügen zu müssen.
- Beispiel: Bestellvorgang
 - Ein Agent überprüft die Bestandsinformationen während
 - ein anderer Agent die Kreditwürdigkeit des Kunden prüft.
 - Beide Agenten arbeiten parallel und wissen nichts von der Entscheidung auf höherer Ebene, ob die Bestellung angenommen wird.

Agent:

- Nimmt seine Umgebung über Sensoren wahr.
- Schlussfolgert und entscheidet sich für bestimmte Handlungen.
- Beeinflusst/verändert die Umgebung durch seine Handlungen.

Agenten sind gekennzeichnet durch Rationalität:

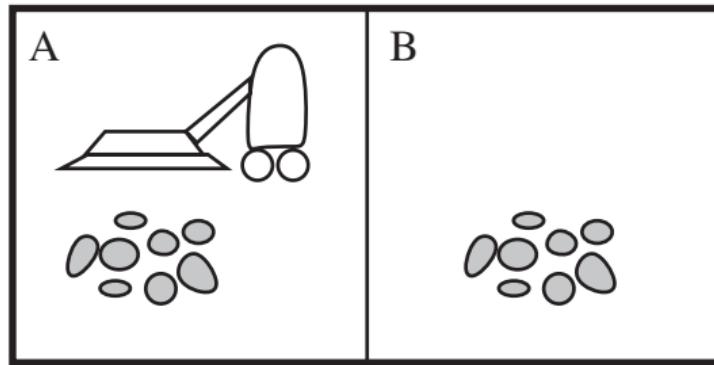
- Zur Optimierung des eigenen Nutzens oder um erfolgreich handeln zu können, muss ein Performanzmaß gegeben sein, ein Maß, um den zu erwartenden Erfolg bestimmen zu können.
- Rationalität bedeutet nicht Allwissenheit, rationales Handeln orientiert sich an
 - dem Performanzmaß,
 - aktuellen und früheren Wahrnehmungen,
 - Wissen über die Umgebung,
 - generellen Handlungsmöglichkeiten.

Eigenschaften von Agenten-Systemen:

- Jeder Agent verfügt nur über unvollständige Informationen. Seine Fähigkeiten reichen nicht aus, um das gesamte Problem zu lösen.
- Es gibt keine globale Instanz zur Steuerung des Systems zur Lösung des Gesamtproblems.
- Wissen und Eingabedaten liegen in dezentraler Form vor.
- Schlussfolgerungsverfahren werden asynchron durchgeführt.

→ starke Analogie zu objektorientierten Programmen

Staubsauger-Welt⁽²⁹⁾:



- Umgebung: Felder A, B, ggf. mit Schmutz
- Sensoren: für Position und Schmutz
- Aktuator: nach rechts/links bewegen; saugen

⁽²⁹⁾Russel, Norvig: Artificial Intelligence – A Modern Approach. Prentice Hall
Wissensbasierte Systeme Geschicht und Anwendungen Agenten

einfaches Agentenprogramm für die Staubsaugerwelt:

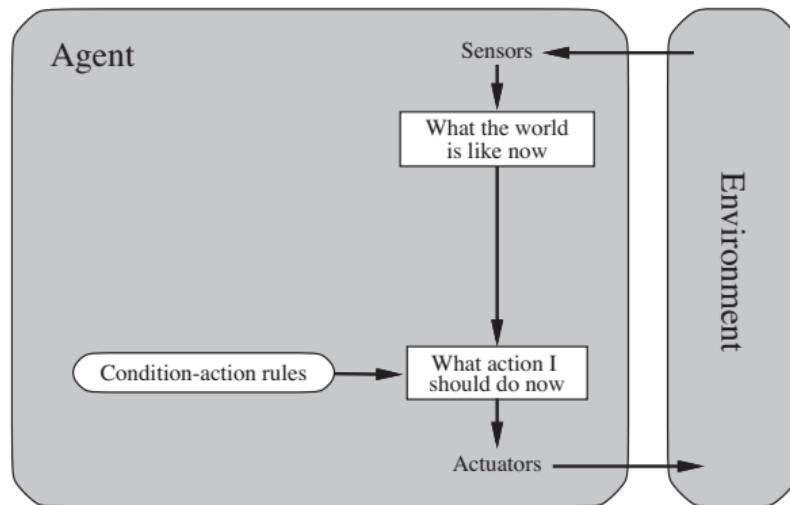
- A oder B schmutzig → saugen
- A sauber → gehe nach rechts
- B sauber → gehe nach links

Anmerkungen:

- Programm berücksichtigt vergangene Wahrnehmungen nicht.
- Wenn alle Felder sauber sind, oszilliert der Sauger zwischen den Feldern.

einfache Reflex-Agenten

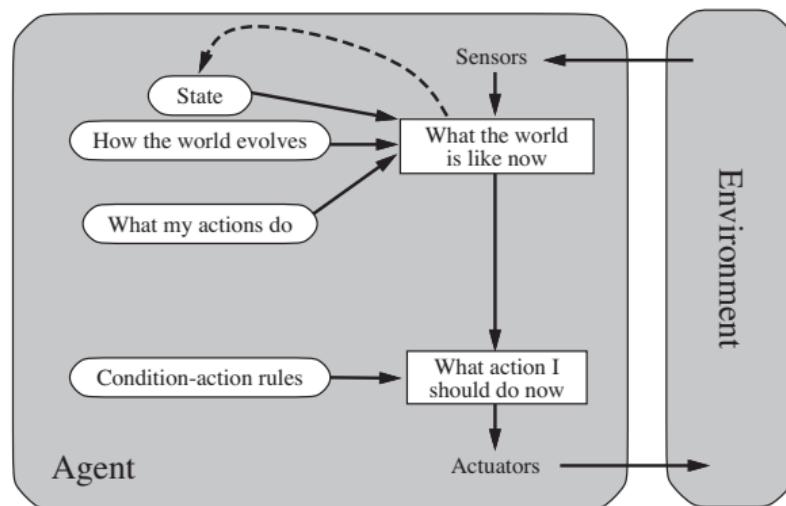
- Aktion hängt nur von aktueller Wahrnehmung ab
- Kein Gedächtnis



Modellbasierte Agenten

- Zustände werden gespeichert
- Modell der Wirklichkeit beschreibt
 - zeitliche Entwicklung der Umgebung unabhängig vom Agenten
 - die Auswirkungen der Aktionen auf die Welt

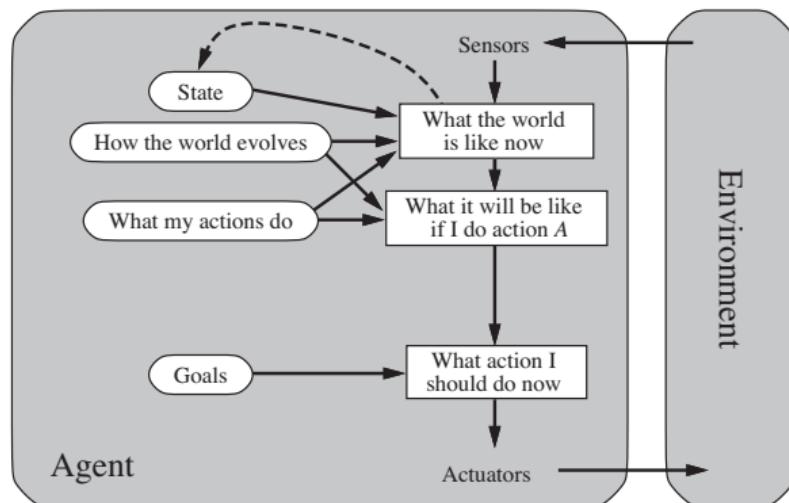
→ verhindert Oszillation



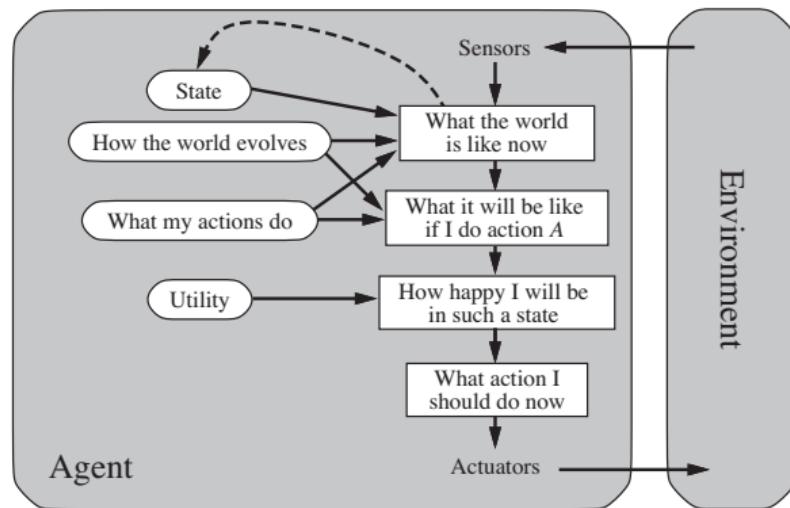
aber keine was-wäre-wenn Simulation

Zielorientierte Agenten

- Bisher: Ziel wurde implizit durch Regeln kodiert.
- Jetzt: explizite Definition von erstrebenswerten Zielen
- Aktionen nicht aus Regeln ableiten, sondern aus Überlegung „was passiert wenn“
→ nutze Planen und Suchstrategien



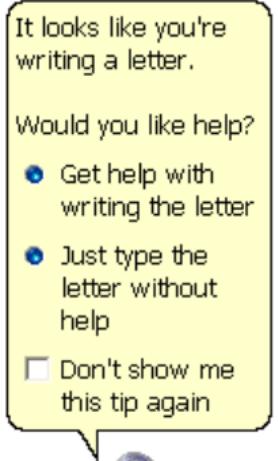
- Lösungen der zielbasierten Agenten sind oft nicht effizient: Jede Entscheidung, die irgendwie zum Ziel führt, ist okay.
- Nutzenfunktion ordnet aktuellen oder zukünftigen Zuständen Bewertungen über die Nützlichkeit zum Erreichen des Ziels zu.
- Vorteil: Günstige Wege zum Ziel können bevorzugt werden.
- Aber: Aufstellen der Nutzenfunktion verlangt viel Information.



- Betonung der Interoperabilität, auch unter nicht-idealnen Bedingungen, z.B. ist Wahrnehmung nie perfekt.
- Erfolge in vielen Teilbereichen verstärken wieder den Blick auf das „Ganze“.

Beispiele:

- Microsofts Heftklammer *Clippy*
- Autonome Staubsauger oder Rasenmäher
- Mobile Informationsagenten



1 Übersicht

- Lernen durch Belohnung
- Planen

2 Geschichte und Anwendungen

- Turing-Test
- neuronale Netze
- Agenten
- Entscheidungsbäume
- Fallbasiertes Schließen
- Sequentielle Entscheidungsprobleme

3 Wissensrepräsentation

4 Zustandsraumsuche

5 Aussagenlogik

6 Prädikatenlogik

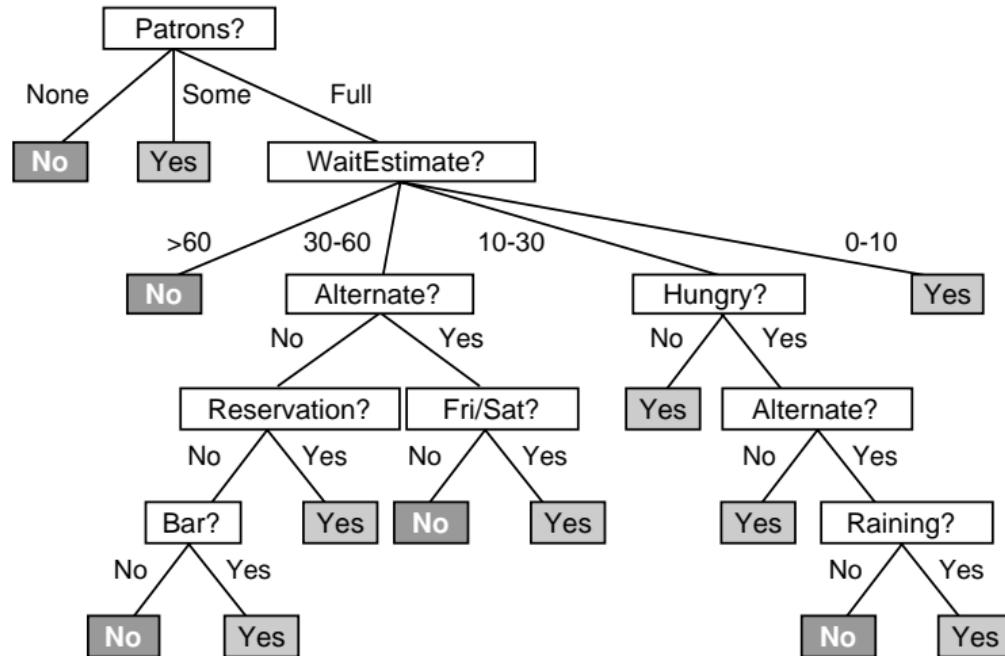
7 Prolog

Die Entscheidung, ob wir bei einem Restaurant-Besuch warten wollen, bis ein Tisch frei wird, treffen wir anhand von verschiedenen Kriterien oder Attributen:

- Alt(ernativ): whether there is a suitable alternative restaurant nearby.
- Bar: whether the restaurant has a comfortable bar area to wait in.
- Fri/Sat: true on Fridays and Saturdays.
- Hun(gry): whether we are hungry.
- Pat(rons): how many people are in the restaurant (values: None, Some, Full).
- Price: the restaurant's price range (+, ++, +++).
- Rain(ing): whether it is raining outside.
- Res(ervation): whether we made a reservation.
- Type: the kind of restaurant (French, Italian, Thai, or Burger).
- Est(imate): the wait estimated by the host (0-10 minutes, 10-30, 30-60, or > 60). Note that every variable has a small set of possible values; the value here is not an integer, rather it is one of four discrete values.

Entscheidungsbäume

Entscheidungsbäume werden zur automatischen Klassifikation genutzt und damit auch zur Lösung von Entscheidungsproblemen.



Trainingsmenge von Beispielen:

Ex.	Alt	Bar	Fri	Hun	Pat	Price	Rain	Res	Type	Est	Goal
x_1	Yes	No	No	Yes	Some	+++	No	Yes	French	0-10	$y_1 = \text{Yes}$
x_2	Yes	No	No	Yes	Full	+	No	No	Thai	30-60	$y_2 = \text{No}$
x_3	No	Yes	No	No	Some	+	No	No	Burger	0-10	$y_3 = \text{Yes}$
x_4	Yes	No	Yes	Yes	Full	+	Yes	No	Thai	10-30	$y_4 = \text{Yes}$
x_5	Yes	No	Yes	No	Full	+++	No	Yes	French	> 60	$y_5 = \text{No}$
x_6	No	Yes	No	Yes	Some	++	Yes	Yes	Italian	0-10	$y_6 = \text{Yes}$
x_7	No	Yes	No	No	None	+	Yes	No	Burger	0-10	$y_7 = \text{No}$
x_8	No	No	No	Yes	Some	++	Yes	Yes	Thai	0-10	$y_8 = \text{Yes}$
x_9	No	Yes	Yes	No	Full	+	Yes	No	Burger	> 60	$y_9 = \text{No}$
x_{10}	Yes	Yes	Yes	Yes	Full	+++	No	Yes	Italian	10-30	$y_{10} = \text{No}$
x_{11}	No	No	No	No	None	+	No	No	Thai	0-10	$y_{11} = \text{No}$
x_{12}	Yes	Yes	Yes	Yes	Full	+	No	No	Burger	30-60	$y_{12} = \text{Yes}$

```
DECISIONTREE( $E$  : examples,  $A$  : attributes,  $default$  : classification)
if  $E = \emptyset$  then
    return  $default$ 
else if all  $E$  have the same classification  $c$  then
    return  $c$ 
else if  $A = \emptyset$  then
    throw Error                                ▷ examples with different classification
else
     $a := \text{CHOOSEATTRIBUTE}(A, E)$ 
     $T :=$  a new decision tree with root  $a$ 
    for all attribute value  $w_i$  of  $a$  do
         $E_i := \{e \in E \mid a(e) = w_i\}$ 
         $T_i := \text{DECISIONTREE}(E_i, A - \{a\}, \text{MAJORITYVAL}(E))$ 
        add a branch to  $T$  with label  $w_i$  and subtree  $T_i$ 
    return  $T$ 
```

Der Aufbau (Induktion) der Bäume erfolgt rekursiv.

Dazu müssen Trainingsdaten vorliegen, also zu jedem Objekt des Datensatzes muss die Klassifikation des Zielattributs bekannt sein.

Bei jedem Induktionsschritt wird das Attribut gesucht, mit welchem sich die Trainingsdaten in diesem Schritt bezüglich des Zielattributs am besten klassifizieren lassen. → CHOOSEATTRIBUTE

Für die Bestimmung der besten Klassifizierung werden Entropie-Maße genutzt.

Das ermittelte Attribut wird nun zur Aufteilung der Daten verwendet. Auf die so entstandenen Teilmengen wird die Prozedur rekursiv angewendet, bis in jeder Teilmenge nur noch Objekte mit einer Klassifikation enthalten sind (Greedy Algorithmus).

Falls nach der Aufteilung eine Klasse leer ist, also kein Beispiel diesen Attributwert hat, nutzen wir eine Default-Klassifikation $\text{MAJORITYVAL}(E)$, die durch die Mehrzahl der Beispiele E an dem Elternknoten gegeben ist.

Generelles Prinzip des Lernens: *Occams Razor*

Bevorzuge die einfachste Hypothese, die konsistent mit allen Beobachtungen ist.

https://de.wikipedia.org/wiki/Ockhams_Rasiermesser

- Von mehreren möglichen hinreichenden Erklärungen für ein und denselben Sachverhalt ist die einfachste Theorie allen anderen vorzuziehen.
- Eine Theorie ist einfach, wenn sie möglichst wenige Variablen und Hypothesen enthält und diese in logischen Beziehungen zueinander stehen, aus denen der zu erklärende Sachverhalt folgt.
- Hintergrund: Je mehr unabhängige Annahmen zur Voraussetzung der Erklärung angenommen werden, desto höher ist die Wahrscheinlichkeit, dass eine davon falsch sein könnte.

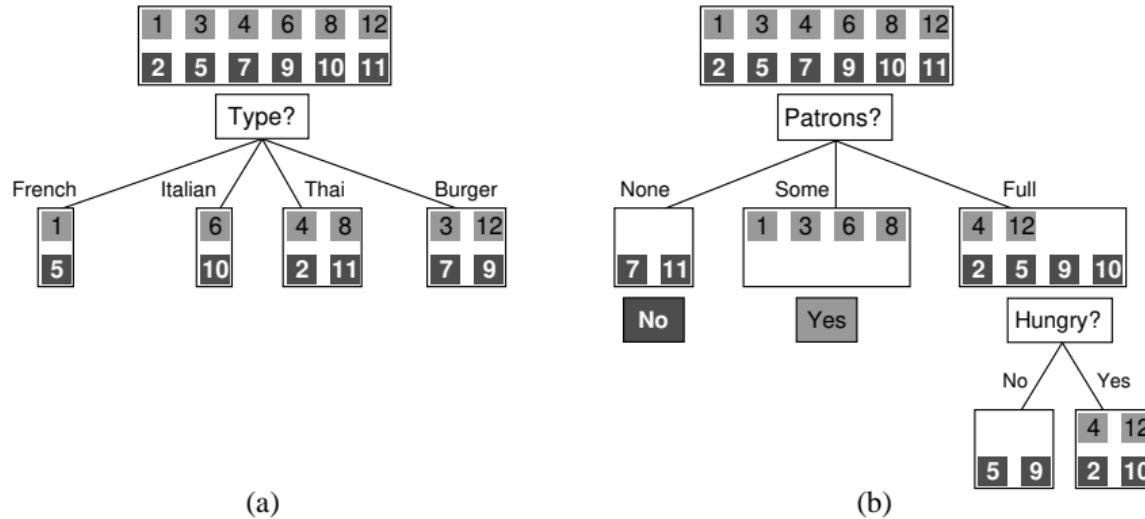
Bei Entscheidungsbäumen wird immer der kleinste Baum gesucht:

Die Chance, dass ein kleiner Baum, der insgesamt viele falsche Entscheidungen trifft, zufälligerweise mit allen Beispielen konsistent ist, ist sehr gering.

Ein kleiner Baum, der konsistent mit allen Beispielen ist, ist daher eher korrekt als ein großer Baum.

Alternativ: Konstruiere den Baum so, dass für jedes Beispiel ein Pfad von der Wurzel zu einem Blatt besteht. Dann werden die gegebenen Beobachtungen zwar exakt gespeichert, aber wir können davon keine sinnvolle Generalisierung auf andere Fälle erwarten, da kein Muster aus den Beispielen extrahiert wird. Man spricht hier von einer Überanpassung des Modells an die Daten, vom sogenannten *Overfitting*.

Type is a poor attribute, because it leaves us with four possible outcomes, each of which has the same number of positive as negative examples.



Patrons is a fairly important attribute, because if the value is *None* or *Some*, then we are left with example sets for which we can answer definitively. If the value is *Full*, we are left with a mixed set of examples.

Diese Intuition von „ziemlich guten“ und „eher nutzlosen“ Attributen wollen wir nun formalisieren. Dazu nutzen wir den Begriff der Entropie:

- Entropie ist ein Maß für die Unbestimmtheit einer Zufallsvariablen.
- Informationserfassung entspricht einer Verringerung der Entropie.

Beispiel:

- Eine Zufallsvariable mit nur einem einzigen Wert - eine Münze, die immer auf Kopf fällt - besitzt keine Unbestimmtheit und somit ist ihre Entropie als null definiert
→ Wir erhalten keine Information, wenn wir ihren Wert beobachten.
- Beim Werfen einer fairen Münze sind die zwei Ereignisse Kopf und Zahl gleichwahrscheinlich und die Entropie ist 1 Bit.
- Eine unfaire Münze, die in 99% der Fälle Kopf zeigt, hat intuitiv weniger Unbestimmtheit als die faire Münze - wenn wir Kopf raten, liegen wir nur in 1% der Fälle falsch - sodass wir ihr eine Entropie zuordnen, die zwar nahe null liegt, aber positiv ist.

Der Informationsgehalt $I(c)$ eines Zeichens c hängt von der Wahrscheinlichkeit p_c seines Auftretens ab:

$$I(c) = \log_2 \left(\frac{1}{p_c} \right) = \log_2 \left(p_c^{-1} \right) = -\log_2(p_c)$$

Beispiele:

- faire Münze: $I(\text{Kopf}) = I(\text{Zahl}) = -\log_2(0,5) = 1$
- fairer Würfel: $I(1) = \dots = I(6) = -\log_2(1/6) \approx 2,58496$

Bei einer fairen Münze oder einem fairen Würfel ist der mittlere Informationsgehalt (Entropie) gleich dem Informationsgehalt des einzelnen Ereignisses.

- $E(\text{Münze}) = 0,5 \cdot I(\text{Kopf}) + 0,5 \cdot I(\text{Zahl}) = -\log_2(0,5) = 1$
- $E(\text{Würfel}) = 1/6 \cdot I(1) + \dots + 1/6 \cdot I(6) = -\log_2(1/6) \approx 2,58496$

Der mittlere Informationsgehalt hat viel mit binärer Codierung zu tun:

- Einen Münzwurf können wir mit dem 1-Bit Block-Code⁽³⁰⁾ C codieren:
 - $C(\text{Kopf}) = 0, C(\text{Zahl}) = 1$
- Um einen Wurf des Würfels zu kodieren, benötigen wir mehr als zwei Bit.
 - Nutzen wir den folgenden Huffman-Code⁽³¹⁾ C , dann erreichen wir den oben berechneten Wert $E(\text{Würfel}) \approx 2,58496$ schon fast:
 - $C(1) = 00, C(2) = 01, C(3) = 100, C(4) = 101, C(5) = 110, C(6) = 111$
 - Bezeichne $L(i)$ die Länge des Codeworts $C(i)$, dann ergibt sich die folgende mittlere Codewort-Länge:

$$\frac{1}{6} \cdot \sum_{i=1}^6 L(i) = \frac{1}{6} \cdot (2 + 2 + 3 + 3 + 3 + 3) \approx 2,667$$

⁽³⁰⁾ Alle Codewörter haben die gleiche Länge. <https://de.wikipedia.org/wiki/Blockcode>

⁽³¹⁾ Bei einem Präfix-Code bildet kein Codewort den Anfang eines anderen Codewortes. → Beim Lesen der kodierten Nachricht ist sofort klar, wann ein Codewort endet, was eine eindeutige Dekodierung ermöglicht. https://en.wikipedia.org/wiki/Prefix_code

Bei einem Würfel, bei dem die Zahlen 1 bis 5 gleich oft, aber die Zahl 6 fünfmal so oft wie die anderen fällt, also $p(1) = \dots = p(5) = 1/10$ und $p(6) = 5/10$, gilt für den mittleren Informationsgehalt:

$$E(\text{unfairer Würfel}) = 1/10 \cdot I(1) + \dots + 1/10 \cdot I(5) + 5/10 \cdot I(6) \approx 2,161$$

Auch diesen Wert erreichen wir fast mit einem einfachen Huffman-Code:

- $C(6) = 0$, $C(1) = 100$, $C(2) = 101$, $C(3) = 110$, $C(4) = 1110$, $C(5) = 1111$
- Bezeichne wieder $L(i)$ die Länge des Codeworts $C(i)$, dann erhalten wir als mittlere Codewort-Länge:

$$1/10 \cdot L(1) + \dots + 1/10 \cdot L(5) + 5/10 \cdot L(6) = 3/10 + 3/10 + 3/10 + 4/10 + 4/10 + 1/2 = 2,2$$

Shannon definierte die Entropie H einer diskreten, gedächtnislosen Quelle (diskrete Zufallsvariable) X über einem endlichen Alphabet S als den Erwartungswert des Informationsgehalts:

$$\text{Entropie}(S) = H(S) = \sum_{c \in S} p_c \cdot I(c) = - \sum_{c \in S} p_c \cdot \log_2(p_c).$$

Dabei ist $p_c = P(X = c)$ die Wahrscheinlichkeit, mit der das Zeichen c des Alphabets auftritt. Setze $0 \cdot \log_2(0) = 0$ entsprechend dem Grenzwert $\lim_{x \rightarrow 0} x \cdot \log_2(x)$.

Für das Münzenbeispiel von oben erhalten wir:

- $H(\text{fair}) = -[0,5 \cdot \log_2(0,5) + 0,5 \cdot \log_2(0,5)] = 1$
- $H(\text{unfair}) = -[0,99 \cdot \log_2(0,99) + 0,01 \cdot \log_2(0,01)] \approx 0,08$

Sei $B(q)$ die Entropie einer booleschen Zufallsvariablen, die mit der Wahrscheinlichkeit q gleich true ist.

$$B(q) = -[q \cdot \log_2(q) + (1 - q) \cdot \log_2(1 - q)]$$

Die Wahrscheinlichkeit, ein bestimmtes Beispiel e_i aus einer Menge $\{e_1, \dots, e_k\}$ auszuwählen, ist $1/k$, und die Wahrscheinlichkeit, aus der Menge eines von ℓ vorgegebenen Beispielen ($\ell \leq k$) auszuwählen, ist ℓ/k .

Wenn eine Trainingsmenge p positive Beispiele und n negative Beispiele enthält, berechnet sich die Entropie des Zielattributes der gesamten Menge also zu

$$H(S) = B\left(\frac{p}{p+n}\right).$$

Die Restaurant-Trainingsmenge hat $p = 6$ positive und $n = 6$ negative Beispiele, die entsprechende Entropie ist demnach $B(6/12) = B(0,5) = 1$ Bit. Ein Test für ein einzelnes Attribut A liefert uns in der Regel nur einen Teil dieses 1 Bit. Wie viel das ist ermitteln wir, indem wir die verbleibende Entropie *nach* dem Attributtest berechnen.

Für das Attribut $A = \text{patrons}$ gibt es drei mögliche Ausprägungen:

- None: Es gibt $p = 0$ positive und $n = 2$ negative Fälle. $\rightarrow B(0/2)$
- Some: Es gibt $p = 4$ positive und $n = 0$ negative Fälle. $\rightarrow B(4/4)$
- Full: Es gibt $p = 2$ positive und $n = 4$ negative Fälle. $\rightarrow B(2/6)$
- Der durch Attributwahl A bedingte mittlere Informationsgehalt (Entropie) ist damit gleich $\frac{2}{12} \cdot B(0/2) + \frac{4}{12} \cdot B(4/4) + \frac{6}{12} \cdot B(2/6) \approx 0,459$.

→ Die Differenz zwischen der ursprünglichen Entropie und der durch die Attributwahl A bedingten Entropie $1 - 0,459 = 0,541$ nennt man Informationsgewinn.

Im Folgenden wollen wir das gerade Gelernte formalisieren.

Ein Attribut A mit d verschiedenen Werten teilt die Trainingsmenge E auf in die Teilmengen E_1, \dots, E_d . Jede Teilmenge E_k enthalte p_k positive und n_k negative Beispiele.

Ein zufällig aus der Trainingsmenge ausgewähltes Beispiel hat den k -ten Wert für das Attribut A mit der Wahrscheinlichkeit $(p_k+n_k)/(p+n)$, der Informationsgehalt (Entropie) ist gleich $B(p_k/(p_k+n_k))$.

Die erwartete restliche Entropie nach dem Testen des Attributes A beträgt:

$$\text{Remainder}(A) = \sum_{k=1}^d \frac{p_k + n_k}{p + n} \cdot B\left(\frac{p_k}{p_k + n_k}\right)$$

Der Informationsgewinn aus dem Attributtest von A ist die erwartete Reduzierung der Entropie:

$$Gain(A) = B\left(\frac{p}{p+n}\right) - Remainder(A)$$

Angewendet auf das Beispiel von Folie 109 erhalten wir:

$$Gain(\text{patrons}) = B(6/12) - \left(\frac{2}{12}B(0/2) + \frac{4}{12}B(4/4) + \frac{6}{12}B(2/6) \right) \approx 0,541 \text{ Bit}$$

$$Gain(\text{type}) = B(6/12) - \left(\frac{2}{12}B(1/2) + \frac{2}{12}B(1/2) + \frac{4}{12}B(2/4) + \frac{4}{12}B(2/4) \right) = 0 \text{ Bit}$$

Das bestätigt unsere Intuition, dass `patrons` ein gutes Attribut ist.

- $B(0) = B(1) = -[0 \cdot \log_2(0) + 1 \cdot \log_2(1)] = -[0 - 0] = 0$
- $B(1/3) = -[1/3 \cdot \log_2(1/3) + 2/3 \cdot \log_2(2/3)] \approx -[-0,52832 - 0,38998] \approx 0,9183$
- $B(1/2) = -[1/2 \cdot \log_2(1/2) + 1/2 \cdot \log_2(1/2)] = -\log_2(1/2) = -(-1) = 1$

ID3-Algorithmus⁽³²⁾: Sei S die Menge der Trainingsbeispiele mit ihrer jeweiligen Klassifizierung, sei $a \in A$ das zu prüfende Attribut, sei $V(a)$ die Menge der möglichen Attributwerte von a und sei S_v die Untermenge von S , für die das Attribut a den Wert v annimmt.

Der Informationsgewinn $Gain(S, a)$, der durch Auswahl des Attributs a erzielt wird, errechnet sich dann als Differenz der Entropie von S und der erwarteten Entropie von S bei Fixierung von a :

$$Gain(S, a) = \text{Entropie}(S) - \sum_{v \in V(a)} \frac{|S_v|}{|S|} \cdot \text{Entropie}(S_v)$$

Wähle ein Attribut mit dem maximalen Gewinn: $\arg \max_{a \in A} \{Gain(S, a)\}$

Diese Wahl führt zur Bevorzugung von Attributen mit vielen Wahlmöglichkeiten und damit zu einem breiten Baum.

⁽³²⁾Iterative Dichotomiser 3, https://en.wikipedia.org/wiki/ID3_algorithm

1 Übersicht

- Lernen durch Belohnung
- Planen

2 Geschichte und Anwendungen

- Turing-Test
- neuronale Netze
- Agenten
- Entscheidungsbäume
- **Fallbasiertes Schließen**
- Sequentielle Entscheidungsprobleme

3 Wissensrepräsentation

4 Zustandsraumsuche

5 Aussagenlogik

6 Prädikatenlogik

7 Prolog

Anstatt Beispiele als Ausgangspunkt für Verallgemeinerungen zu verwenden, wie beim Erstellen von Entscheidungsbäumen, kann man die Beispiele direkt zur Lösung neuer Probleme nutzen.

Ausgangshypothese: Ähnliche Fälle haben ähnliche Lösungen.

- Immanuel Kant: Alles Wissen stammt aus Erfahrung.
- Konfuzius: Der Mensch hat dreierlei Wege klug zu handeln. Erstens durch Nachdenken - das ist der edelste, zweitens durch Nachahmen - das ist der leichteste, und drittens durch Erfahrung - das ist der bitterste.
- Descartes: Jede von mir gelöste Aufgabe wurde zum Muster, welches ich im weiteren für die Lösung anderer Aufgaben benutzte.

„Käpt'n, Käpt'n, wir haben Wasser im Boot!“ – „Dann zieh' doch den Stöpsel 'raus, damit es ablaufen kann“

Case-Based Reasoning (CBR):

- maschinelles Lernverfahren zur Problemlösung durch Analogieschluss.
→ kein regelbasierter, sondern erinnerungsbasierter Prozess
- Zentrales Element: Fallbasis, in der bereits gelöste Probleme als Fall gespeichert sind. Ein Fall besteht mindestens aus einer Problembeschreibung und einer zugehörigen Problemlösung.
- Ziehe zur Lösung eines gegebenen Problems die Lösung eines ähnlichen und früher bereits gelösten Problems heran.

Vorteile:

- Experten müssen keine Regeln explizit festlegen sondern Wissen kann implizit dargestellt werden.
- Wissensbasis wird durch Bearbeitung und Speicherung neuer Fälle ständig erweitert und das System lernt automatisch.

Anwendungsbereiche:

- Rechtsprechung: Argumentation erfolgt häufig und explizit nach Sachlage früherer, vergleichbarer Fälle.
- Medizin: Jeder Patient ist ein Fall, auf den später als Erfahrungswissen zurückgegriffen werden kann.
- e-commerce: Verkaufsagenten suchen Produkte aus dem Angebot heraus, indem sie ähnliche Kunden vergleichen.

„Kunden, die Produkt A kauften, kauften häufig auch Produkt B“

Wichtig: Erklärungskomponente ist beim CBR sehr ausgeprägt, Problemlösungen sind sehr gut verständlich.

Qualität eines CBR-Systems ist abhängig von

- seiner Erfahrung, also dem Umfang der Fallbasis
- seiner Fähigkeit, neue Situationen mit gespeicherten Fällen in Verbindung zu bringen
- seiner Fähigkeit, alte Lösungen an neue Probleme anzupassen
- der Art und Weise, wie neue Lösungen evaluiert und bei Bedarf korrigiert werden
- der Integration neuer Erfahrungen in die Fallbasis

Prozess mit vier Phasen:

- *Retrieve*: Ausgehend zur gegebenen Problembeschreibung in der Fallbasis ein möglichst ähnliches Problem ermitteln.
→ Ähnlichkeit der Problembeschreibungen bestimmen
- *Reuse*: Die Lösung des ähnlichsten Falls als ersten Lösungsvorschlag übernehmen.
- *Revise*: Falls das aktuelle Problem nicht genau so zu lösen ist wie das frühere, überprüfe die zuvor gewonnene Lösung und passe sie gegebenenfalls an die konkreten Bedingungen an.
- *Retain*: Der überarbeitete Fall wird in der Fallbasis gespeichert und steht damit für zukünftige Anfragen zur Verfügung.
→ Auf diese Weise lernt das System mit jedem weiteren gelösten Problem hinzu und verbessert so seine Leistungsfähigkeit.

Wie kann eine Fallbasis realisiert werden? → nächste Folie

Attribut-Wert-Repräsentation: Représentiere einen Fall durch Attribut-Wert-Paare.

- Die Menge der Attribute (A_i) wird entweder für alle Fälle fest vorgegeben oder variiert von Fall zu Fall.
- Jedem Attribut ist ein Wertebereich (Typ) zugeordnet, z.B. Integer oder Text.
- Falls die Attributmenge fest vorgegeben ist, entspricht ein Fall einem n -stelligen Vektor $F = (a_1, \dots, a_n) \in T_1 \times \dots \times T_n$, wobei $a_i \in T_i$ (a_i sind die Werte und T_i die Typen/Wertebereiche).
- Unbekannte Attributwerte können durch die Einführung eines speziellen Symbols *unknown* dargestellt werden. Daraus folgt: $a_i \in T_i \cup \{\text{unknown}\}$.
- Bei variabler Attributmenge ist ein Fall eine Menge $F = \{A_1 = a_1, \dots, A_n = a_n\}$ mit $a_i \in T_i$. Attribute, die nicht vorkommen, sind unbekannt.

Vorteile:

- Es ist eine sehr einfache Repräsentation, die leicht zu verstehen ist.
- Eine Ähnlichkeitsbestimmung ist einfach und effizient möglich.
- Eine Speicherung z.B. in Datenbanken ist einfach und daher ist ein effizientes Retrieval möglich.

Nachteil: Es sind keine strukturellen oder relationalen Informationen repräsentierbar.

Objektorientierte Modelle: Zusammengehörige Attribute werden zu Objekten zusammengefasst. Ein Fall besteht somit aus einer Menge von Objekten. Zwischen diesen Objekten bestehen Beziehungen, die auch Relationen genannt werden.

- Eine *a-kind-of*-Relation (taxonomische Relation) drückt Abstraktions- und Verfeinerungsbeziehungen zwischen Objekten der Domäne aus.
Beispiel: Auto *a-kind-of* Transportmittel.
- Eine *is-part-of*-Relation (kompositionelle Relation) drückt die Zusammensetzung von Objekten aus Teilobjekten aus.
Beispiel: Fenster *is-part-of* Auto.

Nachteile sind aufwändige Ähnlichkeitsberechnung und Retrieval.

Wie kann die Reuse-Phase algorithmisch realisiert werden? Wir benötigen dazu einen **Ähnlichkeitsbegriff** und repräsentieren einen Fall x durch ein Tupel $x = (x_1, \dots, x_n)$, wobei jedes x_i aus dem Wertebereich des i -ten Merkmals stammt.

Bestimme die Gesamt-Ähnlichkeit zweier Fälle $x = (x_1, \dots, x_n)$ und $y = (y_1, \dots, y_n)$ durch einen Abgleich der einzelnen Merkmale:

$$sim(x, y) = f(sim_1(x_1, y_1), \dots, sim_n(x_n, y_n)),$$

Dabei ist sim_i eine reelle Funktion, die die Ähnlichkeit zwischen verschiedenen Werten eines Merkmals bestimmt.

Bei zwei-wertigen Attributen $x_i \in \{0, 1\}$ wird oft die Hamming-Ähnlichkeit genutzt.

$$d_H(x, y) = \sum_{i=1}^n |x_i - y_i| = \sum_{i: x_i \neq y_i} 1$$

Umrechnung in ein Ähnlichkeitsmaß zwischen 0 und 1:

$$\begin{aligned} sim_H(x, y) &= 1 - \frac{d_H(x, y)}{n} = 1 - \frac{\sum_{i=1}^n |x_i - y_i|}{n} \\ &= \frac{n - \sum_{i=1}^n |x_i - y_i|}{n} = \frac{\sum_{i=1}^n (1 - |x_i - y_i|)}{n} \end{aligned}$$

Für ein Ähnlichkeitsmaß s gilt:

$$s(i, j) = s(j, i) \quad 1 = s(i, i) \geq s(i, j) \quad 0 \leq s(i, j) \leq 1$$

Falls einige Attribute wichtiger als andere sind, verwendet man stattdessen oft die gewichtete Hamming-Ähnlichkeit:

$$\begin{aligned} sim_H^w(x, y) &= \frac{\sum_{i=1}^n w_i \cdot (1 - |x_i - y_i|)}{\sum_{i=1}^n w_i} \\ &= \frac{\sum_{i=1}^n w_i - \sum_{i=1}^n w_i \cdot |x_i - y_i|}{\sum_{i=1}^n w_i} \\ &= 1 - \frac{\sum_{i=1}^n w_i \cdot |x_i - y_i|}{\sum_{i=1}^n w_i} = 1 - \frac{\sum_{i: x_i \neq y_i} w_i}{\sum_{i=1}^n w_i} \end{aligned}$$

Verallgemeinerte Ähnlichkeiten:

$$sim(x, y) = \frac{\sum_{i=1}^n w_i \cdot sim_i(x_i, y_i)}{\sum_{i=1}^n w_i}$$

Oft ist die Lösung des (soeben gefundenen) alten Falls keine mögliche Lösung des aktuellen Problems, weil neue Aspekte vorliegen und keine vollständige Gleichheit gegeben ist.

Als *Adaption* bezeichnet man den Vorgang, eine (vorgeschlagene) Lösung, die sich als nicht ganz richtig für eine (gegebene) Problembeschreibung erweist, so zu manipulieren, dass sie besser zu dem Problem passt.

Dabei kann etwas Neues in die alte Lösung eingefügt werden, etwas wird aus der Lösung entfernt, eine Komponente wird gegen eine andere ausgetauscht oder ein Teil der alten Lösung wird transformiert.

Für einige Anwendungen des fallbasierten Schließens, z.B. Klassifikation, Diagnose oder Entscheidungsunterstützung, kann oftmals auf die Adaption der gefundenen Lösung verzichtet werden.

Um Ähnlichkeit und Korrektheit des Auswahlverfahrens bestimmen zu können, ist man auf eine empirische Bewertung angewiesen.

Ein vergleichbares Problem besteht im Bereich des Information-Retrieval. Dort ist eine große Anzahl von Dokumenten gegeben, aus der die für den Anwender relevanten Informationen bestimmt werden müssen.

Dafür gibt es verschiedene Retrieval-Ansätze und -Systeme, die empirisch miteinander verglichen werden müssen.

Hierzu wird eine Leistungskennzahl (Retrieval-Effektivität) von Retrieval-Systemen ermittelt.

Die Begriffe Precision und Recall aus dem Information-Retrieval können auf den Auswahlprozess geeigneter Fälle übertragen werden.

Im Information-Retrieval bezeichnet der Begriff *Precision* die Fähigkeit eines Systems, in einem Anwendungskontext zwischen relevanten und irrelevanten Informationen zu unterscheiden. Die Precision P ist wie folgt definiert:

$$P := \frac{|\{\text{relevante Fälle}\} \cap \{\text{ausgewählte Fälle}\}|}{|\{\text{ausgewählte Fälle}\}|}$$

Falls nur relevante Fälle (aber ggf. nicht alle relevanten Fälle) ausgewählt werden ($\text{Precision} = 1$), ist der repräsentierte Ähnlichkeitsbegriff korrekt.

Beispiel: Es gibt 20 relevante Fälle.

- Das System hat 5 relevante Fälle und keine anderen gefunden. $\rightarrow \text{Precision} = 1$
- System hat 20 relevante Fälle und 20 nicht relevante gefunden. $\rightarrow \text{Precision} = 0,5$

Problem: Menge der relevanten Fälle ist oft nicht bekannt. (Internet-Suchmaschine)

Im Information-Retrieval bezeichnet der Begriff *Recall* die Fähigkeit eines Systems, in einem Anwendungskontext die relevanten Informationen zu bestimmen. Der Recall R ist wie folgt definiert:

$$R := \frac{|\{\text{relevante Fälle}\} \cap \{\text{ausgewählte Fälle}\}|}{|\{\text{relevante Fälle}\}|}$$

Falls alle relevanten Fälle (und evtl. noch weitere nicht relevante Fälle) bestimmt wurden ($\text{Recall} = 1$), ist der repräsentierte Ähnlichkeitsbegriff vollständig.

Beispiel: Es gibt 20 relevante Fälle.

- Das System hat 5 relevante Fälle und keine anderen gefunden. $\rightarrow \text{Recall} = 0,25$
- System hat 20 relevante Fälle und 500 nicht relevante gefunden. $\rightarrow \text{Recall} = 1$

1 Übersicht

- Lernen durch Belohnung
- Planen

2 Geschichte und Anwendungen

- Turing-Test
- neuronale Netze
- Agenten
- Entscheidungsbäume
- Fallbasiertes Schließen
- **Sequentielle Entscheidungsprobleme**

3 Wissensrepräsentation

4 Zustandsraumsuche

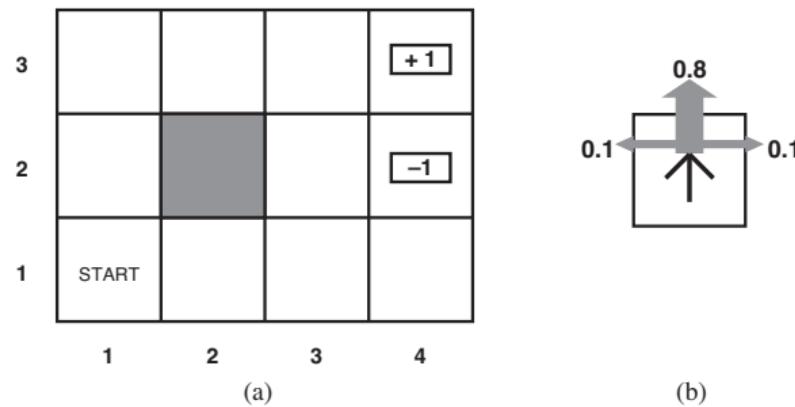
5 Aussagenlogik

6 Prädikatenlogik

7 Prolog

Sequentielle Entscheidungsprobleme

Treffe Entscheidungen in einer stochastischen Umgebung, bei denen der Nutzen eines Agenten von einer Folge von Entscheidungen abhängig ist. Beispiel: Ein Agent befindet sich in der dargestellten 4×3 -Umgebung.



In jedem Schritt muss er eine Aktion auswählen. Die Interaktion mit der Umgebung endet, wenn der Agent einen Zielzustand erreicht hat (markiert mit $+1$ und -1).

Mögliche Aktionen sind in Zustand s durch $A(s)$ gegeben: hoch, runter, links, rechts.

Die Umgebung sei vollständig beobachtbar, sodass der Agent immer weiß, wo er ist.

Wäre die Umgebung deterministisch, könnte sehr einfach ein Plan (= Folge von Aktionen) zum Erreichen des Endzustands gefunden werden: [hoch, hoch, rechts, rechts, rechts]. Leider sind die Aktionen unzuverlässig:

- Jede Aktion erzielt die beabsichtigte Wirkung nur mit einer W'keit von 0,8, sonst bewegt die Aktion den Agenten im rechten Winkel zur beabsichtigten Richtung.
- *Wenn der Agent gegen eine Wand stößt, bleibt er auf demselben Feld stehen.*
Daher sind in jedem Zustand s alle Aktionen hoch, runter, rechts, links erlaubt.

Beispiel: Vom Startfeld (1,1) bewegt die Aktion *hoch* den Agenten mit einer W'keit von 0,8 nach (1,2), mit einer W'keit von 0,1 bewegt er sich nach rechts zu (2,1), mit W'keit 0,1 bewegt er sich nach links, stößt gegen die Wand und bleibt in (1,1) stehen.

Also führt die Sequenz [hoch, hoch, rechts, rechts, rechts] um die Barriere herum und erreicht den Zielzustand (4,3) mit einer W'keit von $0,8^5 = 0,32768$. Es besteht auch eine kleine Chance, das Ziel versehentlich auf dem umgekehrten Weg zu erreichen, nämlich mit einer W'keit von $0,1^4 \cdot 0,8 = 0.00008$, insgesamt führt die Sequenz also mit einer W'keit von 0,32776 zum Ziel.

Das Übergangsmodell (transition model) beschreibt das Ergebnis jeder Aktion in jedem Zustand. Hier ist das Ergebnis stochastisch, daher schreiben wir $P(s' | s, a)$, um die W'keit zu bezeichnen, den Zustand s' zu erreichen, wenn die Aktion a im Zustand s ausgeführt wird.

Annahme: Es handelt sich um *Markov-Übergänge*, d.h. dass die W'keit, s' von s aus zu erreichen, nur von s und nicht vom Verlauf früherer Zustände abhängt. Wir können uns $P(s' | s, a)$ also als eine 3-dimensionale Tabelle vorstellen.

Da wir nicht an irgendeiner Lösung interessiert sind, sondern an einer möglichst guten, in diesem Fall eine möglichst kurze Folge, müssen wir eine Nutzenfunktion angeben.

Umgebungsverlauf

Da das Entscheidungsproblem sequentiell ist, hängt die Nutzenfunktion von einer Folge von Zuständen - dem Umgebungsverlauf - und nicht von einem einzelnen Zustand ab.

Wir legen fest, dass der Agent in jedem Zustand s eine Belohnung $R(s)$ erhält, die positiv oder negativ sein kann, aber begrenzt sein muss. Für unser spezielles Beispiel ist die Belohnung gleich $-0,04$ in allen Zuständen außer den Endzuständen, die die Belohnungen $+1$ bzw. -1 haben.

Der Nutzen eines Umgebungsverlaufs ist (vorerst) einfach die Summe der erhaltenen Belohnungen. → additive Gewinne

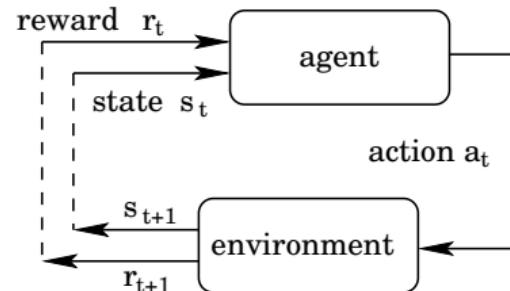
Beispiel: Wenn der Agent nach 10 Schritten den Zustand $+1$ erreicht, beträgt sein Gesamtnutzen 0,6.

Bemerkung: Die negative Belohnung von $-0,04$ gibt dem Agenten einen Anreiz, den Endzustand (4,3) schnell zu erreichen.

Markov-Entscheidungsprozess

Ein sequentielles Entscheidungsproblem für eine vollständig beobachtbare, stochastische Umgebung mit einem Markov-Übergangsmodell und additiven Gewinnen heißt **Markov-Entscheidungsprozess** und besteht aus

- einer Menge S von Zuständen und einem Anfangszustand $s_0 \in S$,
- eine Menge A von möglichen Aktionen, wobei $A(s)$ die möglichen Aktionen im Zustand s angibt,
- einem Übergangsmodell mit W'keiten $P(s' | s, a)$ und
- einer Gewinnfunktion R , die jedem Zustand s einen Wert $r = R(s)$ zuordnet.



Wie kann eine Lösung für ein sequentielles Entscheidungsproblem aussehen?

- Eine festgelegte Aktionssequenz (also ein Plan) kann das Problem nicht lösen, weil der Agent in einem anderen Zustand als dem des Ziels enden könnte.
- Daher muss eine Lösung angeben, was der Agent für jeden Zustand tun soll, den der Agent erreichen kann.

Eine derartige Lösung wird als *Strategie* (englisch policy) bezeichnet. Es ist üblich, eine Strategie als Funktion $\pi : S \rightarrow A$ zu bezeichnen, und $\pi(s)$ ist die von der Strategie π empfohlene Aktion für den Zustand s .

Wenn der Agent eine vollständige Strategie hat, dann weiß der Agent unabhängig vom Ergebnis einer Aktion immer, was als nächstes zu tun ist.

Eine Strategie ist im einfachsten Fall eine Hash-Tabelle, in der zu jedem Zustand eine auszuführende Aktion enthalten ist, es können aber auch komplexe Suchverfahren wie Minimax auf Seite 499 sein.

Bei großen Zustandsräumen wird die Funktion π oft approximiert, dazu eignen sich *Fourierreihen* oder *neuronale Netze*.

Jedes Mal, wenn eine bestimmte Strategie vom Ausgangszustand aus ausgeführt wird, kann die stochastische Natur der Umwelt zu einem anderen Umgebungsverlauf führen.

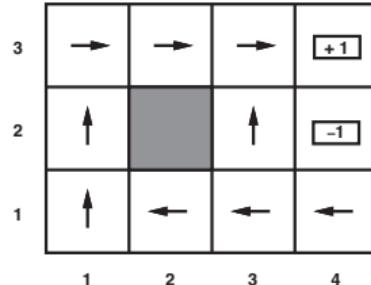
- Die Qualität einer Strategie wird daher anhand des *erwarteten Nutzens* der möglichen Umgebungsverläufe gemessen, die durch diese Strategie möglich sind.
- Eine *optimale Strategie* ist eine Strategie, die den höchsten erwarteten Nutzen bringt. Wir verwenden π^* , um eine optimale Strategie zu bezeichnen.

Ist π^* bekannt, dann entscheidet der Agent, was er tun soll, indem er seine aktuelle Wahrnehmung (über Sensoren) nutzt. Zu dem ermittelten aktuellen Zustand s führt der Agent die Aktion $\pi^*(s)$ aus.

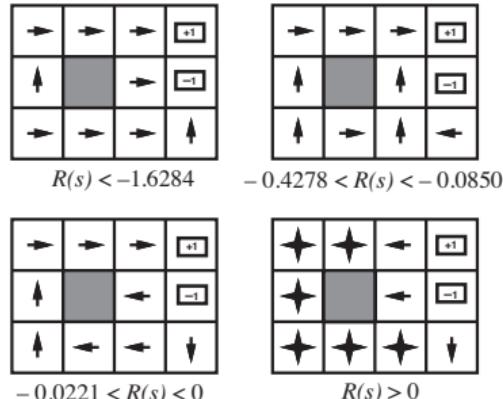
Eine Strategie stellt die Funktion des Agenten explizit dar und ist daher eine Beschreibung eines *einfachen Reflex-Agenten*, der aus den für einen nutzenbasierten Agenten verwendeten Informationen berechnet wird.

Die Frage ist natürlich, wie eine optimale Strategie berechnet werden kann. Das wollen wir uns später ansehen.

Ausgleich zwischen Risiko und Gewinnänderungen



(a)



(b)

- $R(s) \leq -1,6284$: Der Agent läuft direkt auf den nächsten Ausgang zu.
- $-0,4278 \leq R(s) \leq -0,0850$: Der Agent nimmt den kürzesten Weg zum Zustand +1 und akzeptiert das Risiko, in den Zustand -1 zu gelangen.
- $-0,0221 < R(s) < 0$: Gehe keinerlei Risiken ein. In (4,1) und (3,2) bewegt sich der Agent vom Zustand -1 weg.
- $R(s) > 0$: Der Agent vermeidet beide Ausgänge und erhält einen unendlichen Gesamtgewinn, weil er nie einen Terminalzustand erreicht.

Betrachten wir einen Umgebungsverlauf $U([s_0, s_1, \dots, s_n])$. Wir unterscheiden die Entscheidungsfindung bei einem

- **endlichen Horizont:** Es gibt eine feste Zeit N , was danach passiert, ist egal, also $U([s_0, s_1, \dots, s_{N+k}]) = U([s_0, s_1, \dots, s_N])$ für alle $k > 0$.
 - Beispiel: Der Agent befindet sich im Feld (3,1) und $N = 3$. Um Feld (4,3) mit dem Wert +1 erreichen zu können, muss der Agent direkt darauf zugehen: Aktion hoch
 - Für $N = 100$ könnte eine sichere Route gewählt werden: Aktion links

Bei einem endlichen Horizont kann sich die optimale Aktion für einen bestimmten Zustand mit der Zeit ändern → optimale Taktik ist nicht stationär.

- **unendlichen Horizont:** Es gibt kein festes Zeitlimit und daher auch keinen Grund, sich zu unterschiedlichen Zeiten im gleichen Zustand unterschiedlich zu verhalten.
→ Die optimale Aktion hängt nur vom aktuellen Zustand ab und die optimale Taktik ist **stationär**.

Achtung: Unendlicher Horizont bedeutet nicht unbedingt, dass alle Zustandsfolgen unendlich sind; es gibt nur keine feste Deadline.

Der Nutzen einer Zustandsfolge $[s_0, s_1, s_2, \dots]$ ist:

$$U([s_0, s_1, s_2, \dots]) = R(s_0) + \gamma \cdot R(s_1) + \gamma^2 \cdot R(s_2) + \dots = \sum_{t=0}^{\infty} \gamma^t \cdot R(s_t)$$

Der *Diskontierungsfaktor* γ ist eine Zahl zwischen 0 und 1.

- Für $\gamma = 1$ erhalten wir unsere oben im Beispiel genutzte Nutzenfunktion: Alle Gewinne werden gleich gewichtet. → additive Gewinne
- Für $\gamma < 1$ werden die weit in der Zukunft liegenden Gewinne schwächer gewichtet. → verminderte Gewinne
- Wenn γ nahe 0 liegt, werden Gewinne in der fernen Zukunft vernachlässigt.

Der *Diskontierungsfaktor* γ wird eingeführt, damit auch bei unendlich langen Folgen, also insbesondere bei unendlichem Horizont, der Nutzen endlich ist.

- Die Gewinne seien durch R_{\max} begrenzt und es gelte $\gamma < 1$, dann gilt

$$U([s_0, s_1, s_2, \dots]) = \sum_{t=0}^{\infty} \gamma^t \cdot R(s_t) \leq \sum_{t=0}^{\infty} \gamma^t \cdot R_{\max} = \frac{R_{\max}}{1 - \gamma}$$

aufgrund der geometrischen Reihe:

$$\sum_{t=0}^{\infty} \gamma^t = \frac{1}{1 - \gamma}$$

- Wenn die Umgebung Terminalzustände enthält und der Agent irgendwann garantiert einen Terminalzustand erreicht, kann $\gamma = 1$ gewählt werden.

Eine Strategie, die garantiert einen Terminalzustand erreicht, heißt *korrekte Strategie*.

Vergleiche die *erwarteten Nutzen*, die sich bei der Ausführung der Strategien ergeben. Der Nutzen einer Zustandsfolge $[s_0, s_1, s_2, \dots]$ war definiert als:

$$\begin{aligned}U([s_0, s_1, s_2, \dots]) &= R(s_0) + \gamma \cdot R(s_1) + \gamma^2 \cdot R(s_2) + \gamma^3 \cdot R(s_3) + \dots \\&= R(s_0) + \gamma \cdot (R(s_1) + \gamma \cdot R(s_2) + \gamma^2 \cdot R(s_3) + \dots) \\&= R(s_0) + \gamma \cdot U([s_1, s_2, \dots])\end{aligned}$$

Der *erwartete Nutzen* $U^\pi(s)$ eines Zustands s bei Ausführen von π beginnend in s ist daher der unmittelbare Gewinn für diesen Zustand plus dem erwarteten verminderen Gewinn des nächsten Zustandes.

$$U^\pi(s) = R(s) + \gamma \cdot \sum_{s'} P(s' | s, \pi(s)) \cdot U^\pi(s')$$

Achtung: $U^\pi(s)$ und $R(s)$ sind unterschiedliche Quantitäten: $R(s)$ ist der „kurzfristige“ Gewinn, sich in s zu befinden, während $U^\pi(s)$ der „langfristige“ Gesamtgewinn ab s ist.

Vergleich von Strategien

Von allen Strategien, die ein Agent zur Ausführung beginnend in s wählen kann, hat eine den höchsten erwarteten Nutzen; diese nennen wir π_s^* , also $\pi_s^* = \arg \max_{\pi} U^{\pi}(s)$.

Die Strategie π_s^* ist insbesondere eine optimale Strategie für den Ausgangszustand s .

Eine optimale Strategie und daher optimale Nutzen erhalten wir, wenn der Agent immer die beste Aktion wählt:

$$U(s) = R(s) + \gamma \cdot \max_{a \in A(s)} \sum_{s'} P(s' | s, a) \cdot U(s')$$

3	0.812	0.868	0.918	+1
2	0.762		0.660	-1
1	0.705	0.655	0.611	0.388

1 2 3 4

Links: Die Nutzen der Zustände für $\gamma = 1$ und $R(s) = -0.04$ für Nichtterminalzustände s .

Bei unendlichen Horizonten ist eine optimale Strategie sogar unabhängig vom Ausgangszustand.

Wir wollen nun eine optimale Strategie berechnen. Für eine optimale Strategie hatten wir bereits festgestellt:

$$U(s) = R(s) + \gamma \cdot \max_{a \in A(s)} \sum_{s'} P(s' | s, a) \cdot U(s')$$

Diese Gleichung nennt man *Bellman-Gleichung*. Bei n möglichen Zuständen gibt es n Bellman-Gleichungen, eine für jeden Zustand.

Die n Gleichungen enthalten n Unbekannte, nämlich die Nutzen der Zustände.
Problem: Die Gleichungen sind nicht-linear, weil \max kein linearer Operator ist, daher hilft uns die lineare Algebra hier nicht. Lösung: Nutze einen iterativen Ansatz.

$$U_{i+1}(s) = R(s) + \gamma \cdot \max_{a \in A(s)} \sum_{s'} P(s' | s, a) \cdot U_i(s')$$

Beginne mit zufälligen Ausgangswerten $U_0(s)$ für die Nutzen der Zustände $s \in S$; die Aktualisierung wird bei jeder Iteration auf alle Zustände gleichzeitig angewendet.

```
function VALUEITERATION(mdp : MDP,  $\varepsilon$  : double)
  ▷ mdp contains a set of states  $S$ , a set of actions  $A$ , probabilities  $P(s' | s, a)$ ,
  ▷ the reward function  $R$  and the discount factor  $\gamma$ 
  initialize  $U'(s) := 0$  for each state  $s \in S$ 
  repeat
     $U := U'$ ,  $\delta := 0$ 
    for all states  $s \in S$  do
       $U'[s] := R[s] + \gamma \cdot \max_{a \in A(s)} \sum_{s'} P(s' | s, a) \cdot U[s']$ 
      if  $|U'[s] - U[s]| > \delta$  then
         $\delta := |U'[s] - U[s]|$ 
    until  $\delta < \varepsilon(1 - \gamma)/\gamma$       (only valid for  $0 < \gamma < 1$ )
  return  $U$ 
```

Hier bezeichnet ε den maximal erlaubten Fehler im Nutzen der Zustände.

Frage: Konvergieren die Werte bzw. terminiert der Algorithmus?

Sei (M, d) ein metrischer Raum. Eine Abbildung $\varphi : M \rightarrow M$ heißt *Kontraktion*, wenn es eine Zahl $\lambda \in [0, 1)$ gibt, mit der für alle $x, y \in M$ gilt:

$$d(\varphi(x), \varphi(y)) \leq \lambda \cdot d(x, y)$$

Bedeutung: Eine Funktion φ , die bei aufeinanderfolgender Anwendung auf zwei unterschiedlichen Eingaben zwei Ausgabewerte erzeugt, die „enger beisammen“ liegen als die ursprünglichen Eingaben, und zwar mindestens um einen konstanten Faktor.

Beispiel: Die Funktion $\varphi : x \mapsto x/2$ ist eine Kontraktion, denn wenn wir zwei Zahlen durch 2 dividieren, wird ihre Differenz halbiert. Die Funktion hat den *Fixpunkt* 0.

Kontraktionen haben zwei wichtige Eigenschaften:

- Eine Kontraktion φ hat nur einen Fixpunkt; gäbe es zwei Fixpunkte, würden sie sich bei Anwendung der Funktion nicht annähern und φ wäre keine Kontraktion.
- Wenn die Funktion auf ein Argument angewendet wird, muss sie dem Fixpunkt näher kommen (weil sich der Fixpunkt nicht bewegt); eine wiederholte Anwendung einer Kontraktion kommt also letztendlich dem Fixpunkt beliebig nahe.

Sei U_i der Nutzenvektor für alle Zustände in der i -ten Iteration. Einen Iterationsschritt können wir dann als $U_{i+1} := B U_i$ für einen geeigneten Operator B schreiben.

Um Distanzen zwischen Nutzenvektoren zu messen, verwenden wir die **Max-Norm**, die die „Länge“ eines Vektors als absoluten Wert seiner größten Komponente misst:

$$\|U\| = \max_s |U(s)|$$

Dann ist zu zeigen, dass $\|B U_i - B U'_i\| \leq \gamma \cdot \|U_i - U'_i\|$ gilt. Also: Die Aktualisierung in einer Iteration ist eine Kontraktion um einen Faktor γ im Raum der Nutzenvektoren.

Idee: Aus der Mathematik wissen wir, dass für Funktionen $f, g : M \rightarrow M$ gilt:

$$|\max_a f(a) - \max_a g(a)| \leq \max_a |f(a) - g(a)|$$

Wenn man dies auf $|(B U_i - B u')(s)|$ anwendet, sieht man, dass der Bellman-Operator eine Kontraktion ist.

Anmerkung: Wenn eine Aktion in einem Zustand deutlich besser als alle anderen Aktionen in dem Zustand ist, muss die genaue Größe der Nutzen der beteiligten Zustände nicht genau sein.

Eigentlich wollen wir eine optimale Strategie π^* berechnen und keine Nutzenfunktion. Aber die Nutzenfunktion U kann dabei helfen.

Die Nutzenfunktion U erlaubt es dem Agenten, Aktionen nach dem *Prinzip des maximalen erwarteten Nutzens* auszuwählen. Der Agent wählt die Aktion, die den erwarteten Nutzen des nachfolgenden Zustandes maximiert:

$$\pi^*(s) = \arg \max_{a \in A(s)} \sum_{s'} P(s' | s, a) \cdot U(s')$$

Über den Umweg der Nutzenfunktion haben wir eine optimale Strategie berechnet.

Wert-Iteration

3	0.812	0.868	0.918	+ 1
2	0.762		0.660	- 1
1	0.705	0.655	0.611	0.388

Beispiel: Der Agent befindet sich auf dem Feld (3,1).

$$\pi^*(s) = \arg \max_{a \in A(s)} \sum_{s'} P(s' | s, a) \cdot U(s')$$

$$\max_{a \in A(s)} \left\{ \begin{array}{ll} 0.8 \cdot U((3, 2)) + 0.1 \cdot U((2, 1)) + 0.1 \cdot U((4, 1)) & \text{hoch} \\ = 0.8 \cdot 0.660 + 0.1 \cdot 0.655 + 0.1 \cdot 0.388 = 0.6323 & \\ 0.8 \cdot U((3, 1)) + 0.1 \cdot U((2, 1)) + 0.1 \cdot U((4, 1)) & \text{runter} \\ = 0.8 \cdot 0.611 + 0.1 \cdot 0.655 + 0.1 \cdot 0.388 = 0.5931 & \\ \textcolor{blue}{0.8 \cdot U((2, 1)) + 0.1 \cdot U((3, 1)) + 0.1 \cdot U((3, 2))} & \text{links} \\ = 0.8 \cdot 0.655 + 0.1 \cdot 0.611 + 0.1 \cdot 0.660 = 0.6511 & \\ 0.8 \cdot U((4, 1)) + 0.1 \cdot U((3, 1)) + 0.1 \cdot U((3, 2)) & \text{rechts} \\ = 0.8 \cdot 0.388 + 0.1 \cdot 0.611 + 0.1 \cdot 0.660 = 0.4375 & \end{array} \right.$$

Eine optimale Strategie kann auch mittels der Strategie-Iteration ermittelt werden. Der Algorithmus beginnt mit einer Strategie π_0 und wechselt zwischen zwei Schritten:

- Auswertung: Für eine gegebene Strategie π_i wird $U_i = U^{\pi_i}$ berechnet, also der Nutzen jedes Zustandes, wenn π_i ausgeführt wird.
- Verbesserung: Es wird eine neue Strategie π_{i+1} berechnet, die basierend auf U_i immer einen Schritt vorausschaut.

Der Algorithmus terminiert, wenn die Verbesserung keine Änderung im Nutzen mehr erbringt. Dann ist die Nutzenfunktion U_i ein Fixpunkt und eine Lösung der Bellman-Gleichungen. Also muss π_i eine optimale Strategie sein.

endlich viele Strategien über einem endlichen Zustandsraum und jede Iteration liefert eine bessere Strategie → Strategie-Iteration terminiert

```
function POLICYITERATION(mdp : MDP)
    ▷ mdp contains a set of states  $S$ , a set of actions  $A$ , probabilities  $P(s' | s, a)$ ,
    ▷ the reward function  $R$  and the discount factor  $\gamma$ 
    initialize  $U(s) := 0$  for each state  $s \in S$ 
    repeat
         $U := \text{POLICYEVALUATION}(\pi, U, mdp)$ 
        changed := false
        for all states  $s \in S$  do
            if  $\max_{a \in A(s)} \sum_{s'} P(s' | s, a) \cdot U[s'] > \sum_{s'} P(s' | s, \pi[s]) \cdot U[s']$  then
                 $\pi[s] := \arg \max_{a \in A(s)} \sum_{s'} P(s' | s, a) \cdot U[s']$ 
                changed := true
        until not changed
    return  $\pi$ 
```

Wie ist die Funktion POLICYEVALUATION zu implementieren?

Die auszuführende Aktion ist in jedem Zustand durch die Strategie festgelegt. Bei der i -ten Iteration spezifiziert die Strategie π_i die Aktion $\pi_i(s)$ im Zustand s .

Wir müssen also eine vereinfachte Version der Bellman-Gleichung lösen:

$$U_i(s) = R(s) + \gamma \cdot \sum_{s'} P(s' | s, \pi_i(s)) \cdot U_i(s')$$

Diese Gleichungen sind linear. Für n Zustände haben wir n Gleichungen mit n Unbekannten und können mittels Standardmethoden der linearen Algebra in Zeit $\mathcal{O}(n^3)$ die Gleichungen lösen.

Für kleine Werte von n ist das vielleicht akzeptabel, nicht aber für größere Werte. Hier kann eine vereinfachte Auswertung helfen, die iterativ k -mal durchlaufen wird:

$$U_i^{t+1}(s) := R(s) + \gamma \cdot \sum_{s'} P(s' | s, \pi_i(s)) \cdot U_i^t(s')$$

Dadurch erhalten wir eine hinreichend genaue Abschätzung der Nutzen.

1 Übersicht

2 Geschichte und Anwendungen

- Turing-Test
- neuronale Netze
- Agenten
- Entscheidungsbäume
- Fallbasiertes Schließen
- Sequentielle Entscheidungsprobleme

• Lernen durch Belohnung

- Planen

3 Wissensrepräsentation

4 Zustandsraumsuche

5 Aussagenlogik

6 Prädikatenlogik

7 Prolog

Im vorherigen Kapitel wurden Belohnungen eingeführt, um optimale Strategien in Markov-Entscheidungsprozessen zu definieren. Eine optimale Strategie maximiert den erwarteten Gesamtgewinn.

Die Aufgabe des verstärkenden Lernens, auch Lernen durch Belohnung genannt, ist es, anhand beobachteter, oft verzögerter Belohnungen eine (fast) optimale Strategie für die Umgebung zu lernen.

Während der Agent im letzten Kapitel ein vollständiges Übergangsmodell besitzt und die Belohnungsfunktion kennt, gehen wir hier von keinerlei Vorwissen aus. Der lernende Agent kennt

- das Übergangsmodell nicht, dass durch die W'keiten $P(s' | s, a)$ gegeben ist, nach Ausführen der Aktion a aus dem Zustand s in den Zustand s' zu gelangen.
- eventuell die möglichen Aktionen in einem Zustand nicht.
- auch nicht die Gewinnfunktion R , die die Belohnung $R(s)$ für jeden Zustand $s \in S$ angibt, es ist nur die letzte Belohnung r bekannt.

→ unbekannter Markov-Entscheidungsprozess

- Ein nutzenbasierter Agent lernt eine Nutzenfunktion für Zustände und verwendet diese, um Aktionen auszuwählen, die den erwarteten Ergebnisnutzen maximieren. Dazu wird ein Übergangsmodell benötigt: Welche Auswirkung hat eine Aktion? Welcher Zustand s' wird erreicht, wenn im Zustand s die Aktion a ausgeführt wird? Welche Aktionen sind in einem Zustand erlaubt? Nur dann kann der Agent die Nutzenfunktion auf die Ergebniszustände anwenden.
- Ein Q-Learning-Agent lernt eine Aktion-Nutzen-Funktion $Q : A \times S \rightarrow \mathbb{R}$, oft Q-Funktion genannt, die den erwarteten Nutzen einer bestimmten Aktion in einem bestimmten Zustand angibt. Eine Aktion kann in verschiedenen Zuständen unterschiedlichen Nutzen haben.
Ein Q-Learning-Agent benötigt kein Übergangsmodell. Er kann die erwarteten Nutzen für die ihm zur Verfügung stehenden Möglichkeiten vergleichen, ohne dass er die Ergebnisse kennen muss.
- Ein Reflex-Agent lernt eine Strategie, die direkt von Zuständen auf Aktionen abbildet.

Lernen durch Belohnung ist nicht durch Methoden oder Algorithmen charakterisiert, sondern durch eine Klasse von Lernproblemen. Die Interaktion eines lernenden Agenten mit seiner Umwelt ist als Markov-Entscheidungsproblem formuliert.

Man unterscheidet zwei Arten des verstärkenden Lernens:

- *passives verstärkendes Lernen*: Die Strategie des Agenten ist festgelegt, im Zustand s führt er die Aktion $\pi(s)$ aus. Er hat nur die Aufgabe, die Nutzen von Zuständen (oder von Zustand/Aktion-Paaren) zu lernen, also zu lernen, wie gut die Strategie ist.

Es kann erforderlich sein, auch ein Übergangsmodell zu lernen.

- *aktives verstärkendes Lernen*: Der Agent muss außerdem lernen, was zu tun ist, er muss also die Strategie lernen.

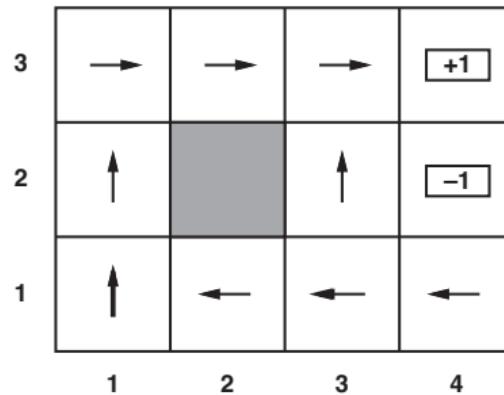
Der wichtigste Aspekt ist die *Exploration*: Der Agent muss so viel wie möglich über seine Umgebung in Erfahrung bringen, um zu lernen, wie er sich darin verhalten soll.

Lernen durch Belohnung

Übersicht: Bei allen Problemen ist die Menge der Zustände S und die Menge der möglichen Aktionen A bekannt.

	außerdem gegeben	gesucht
MDP	Gewinnfunktion R und W'keiten $P(s' s, a)$	optimale Strategie π^* und Nutzenfunktion U
passives Lernen	reward $r = R(s)$ der letzten Aktion, Strategie π	W'keiten $P(s' s, a)$ und Nutzen U^π
aktives Lernen	$r = R(s)$ der letzten Aktion	W'keiten $P(s' s, a)$, optimale Strategie π^* und U

Die W'keiten $P(s' | s, a)$ können durch relative Häufigkeiten (Gesetz der großen Zahlen) approximiert werden: Beobachte, wie oft jedes Aktionsergebnis auftritt und schätze die W'keit $P(s' | s, a)$ aus der Häufigkeit, wie oft s' erreicht wird, wenn wir Aktion a in Zustand s ausführen.



3	0.812	0.868	0.918	+1
2	0.762		0.660	-1
1	0.705	0.655	0.611	0.388
	1	2	3	4

Adaptive dynamische Programmierung: Aus den beobachteten, relativen H ufigkeiten wird die W'keit $P(s' | s, a)$ gesch tzt. Basierend auf diesen Sch tzungen wird der Nutzen der Zust nde berechnet, das Verfahren konvergiert relativ schnell.

$$U^\pi(s) = R(s) + \gamma \cdot \sum_{s'} P(s' | s, \pi(s)) \cdot U^\pi(s')$$

Ein Problem sind gro e Zustandsr ume, weil hier die aus dem letzten Kapitel bekannte Funktion **POLICY EVALUATION** mit Laufzeit $\mathcal{O}(n^3)$ genutzt wird.

```
function PASSIVE-ADP-AGENT( $s'$  : state,  $r'$  : reward)
```

▷ s, a, π, mdp, U, N, M are global variables, and $s \times a \rightarrow s'$ gives reward r'

```
if  $s'$  is new then
```

```
     $U[s'] := r', R[s'] := r'$ 
```

```
if  $s$  is not null then
```

```
    increment  $N[s, a]$  and  $M[s', s, a]$ 
```

```
    for all  $t$  such that  $M[t, s, a] \neq 0$  do
```

```
         $P[t, s, a] := M[t, s, a] / N[s, a]$ 
```

```
 $U := \text{POLICYEVALUATION}(\pi, U, mdp)$ 
```

```
if  $s'$  is terminal state then
```

```
     $s := \text{null}, a := \text{null}$ 
```

```
else  $s := s', a := \pi[s']$ 
```

```
return  $a$ 
```

Der Wert $N[s, a]$ gibt an, wie oft die Aktion a in Zustand s ausgefhrt wurde, und $M[s', s, a]$ gibt an, wie oft Zustand s' erreicht wurde, wenn die Aktion a im Zustand s angewendet wird. Der Wert $P[t, s, a]$ ist eine Schtzung fr $P(t | s, a)$.

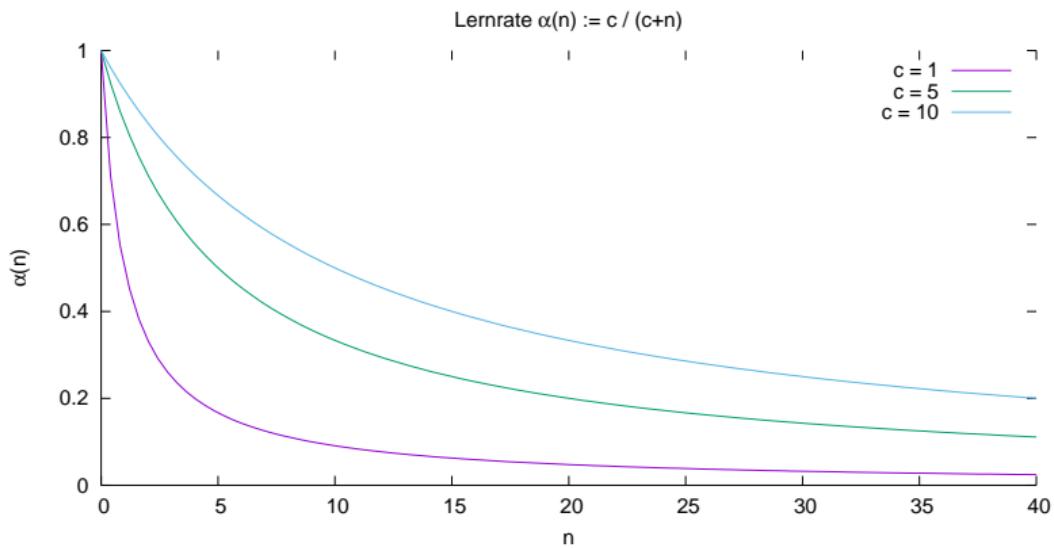
Idee: Vergleiche Soll- und Ist-Wert und nutze deren Differenz Δ , um den Soll-Wert etwas in Richtung Ist-Wert anzupassen. → *Temporal-Difference-Learning*

```
function PASSIVE-TD-AGENT( $s'$  : state,  $r'$  : reward)
   $\triangleright s, a, r, \pi, U, N$  are global variables, and  $s \times a \rightarrow s'$  gives reward  $r'$ 
  if  $s'$  is new then
     $U[s'] := r'$ 
  if  $s$  is not null then
    increment  $N[s]$ 
     $\Delta := r + \gamma \cdot U[s'] - U[s]$ 
     $U[s] := U[s] + \alpha(N[s]) \cdot \Delta$ 
  if  $s'$  is terminal state then
     $s := \text{null}, a := \text{null}, r = \text{null}$ 
  else  $s := s', a := \pi[s'], r = r'$ 
  return  $a$ 
```

Dabei ist α die *Lernrate*, $U[s]$ ist die Sch tzung f r $U(s)$ und daher der Soll-Wert, schlie lich ist $r + \gamma \cdot U[s']$ der Ist-Wert.

passives verstrkendes Lernen

Die **Lernrate** α wird oft als Funktion gewhlt, die abfllt, je hufiger der Zustand besucht wurde, z.B. $\alpha(n) = c/(c+n)$ fr eine geeignete Konstante c . Dann konvergiert $U(s)$ auf den korrekten Wert.



Ein passiv lernender Agent hat eine feste Strategie, die sein Verhalten bestimmt. Er berechnet nur den Nutzen der Zustände. Ein *aktiver Agent* muss entscheiden, welche Aktionen er ausführt, also eine optimale Strategie π^* lernen, er muss die Ergebnis-W'keiten für alle Aktionen lernen sowie die Nutzen der Zustände:

$$U(s) = R(s) + \gamma \cdot \sum_{s'} P(s' | s, \pi^*(s)) \cdot U(s')$$

Idee: Lerne iterativ wie beim ADP- oder TD-Agenten das Übergangsmodell, also die W'keiten $P(s' | s, a)$, und eine Schätzung für U .

Wir bezeichnen einen Agenten als *gierig*, wenn er im nächsten Schritt die Aktion wählt, die (vermeintlich) den erwarteten Nutzen maximiert:

$$\pi^*(s) := \arg \max_{a \in A(s)} \sum_{s'} P(s' | s, a) \cdot U(s') \quad \text{„gierig“}$$

Problem: Solange nicht alle Wege gen gigend oft gegangen wurden, sind die Sch tzungen f r die W kten $P(s' | s, a)$, also das  bergangsmodell, zu ungenau und die gierige Auswahl f hrt zu suboptimalen L sungen.

Dies l sst sich vermeiden, wenn der Agent durch *Exploration* die „wahre Umgebung“ kennen lernt. Das f hrt zwar vielleicht zuerst in einen schlechteren Zustand, liefert langfristig aber vielleicht bessere Nutzen.

Eine reine Greedy-Strategie kann dazu f hren, dass keine optimale L sung gefunden wird. Eine reine Exploration zur Verbesserung des eigenen Wissens hat keinen Wert, wenn dieses Wissen niemals genutzt wird. Daher: Je mehr man wei , desto weniger Exploration ist erforderlich. → Der Agent w hlt manchmal eine zuf llige Aktion aus, sonst folgt er der gierigen Strategie. Formal nutzt man eine Explorationsfunktion f :

$$f(u, n) = \begin{cases} R^+(s) & \text{falls } n < N \\ u & \text{sonst} \end{cases}$$

Dabei ist N ein fest gew hlter Wert und R^+ eine optimistische Sch tzung der h chsten Belohnung. → Jedes Aktion-Zustand-Paar wird mindestens N -mal ausprobiert.

Was erreicht man dadurch? Als Aktualisierungsgleichung erhalten wir:

$$U^+(s) := R(s) + \gamma \cdot \max_{a \in A(s)} f \left(\sum_{s'} P(s' | s, a) \cdot U^+(s'), N(s, a) \right)$$

Dabei bezeichnet $N(s, a)$ die Anzahl, wie oft die Aktion a im Zustand s ausprobiert wurde.

Literatur zu diesem Thema ist im Web frei verf gbar:

- L.P. Kaelbling, M.L. Littman, and A.W. Moore. Reinforcement learning: A survey. *Journal of Artificial Intelligence Research (JAIR)*, 4:237–285, 1996.
- R.S. Sutton and A.G. Barto. *Reinforcement learning - an introduction*. Adaptive computation and machine learning. MIT Press, 1998.
- C. Szepesv ri. *Algorithms for Reinforcement Learning*. Synthesis Lectures on Artificial Intelligence and Machine Learning. Morgan & Claypool Publishers, 2010.

Temporal-Difference-Learning am Beispiel Tic-Tac-Toe: Wie kann der Computer aus vielen Spielen selbstständig lernen? Wir gehen hier davon aus, dass wir einen Agenten trainieren wollen, der Spieler X ersetzt.

Zustände stellen wir bspw. als 9-Tupel dar: $(\times, -, \circ, -, \times, -, \circ, -, \times)$

Jedem Zustand $s \in S$ wird eine Zahl $U(s) \in [0, 1]$ zugewiesen. Diese Zahl beschreibt die Chance des Gewinns aus der Sicht eines der Spieler für Zustand s . Implementiert ist U z.B. als Hash-Tabelle.

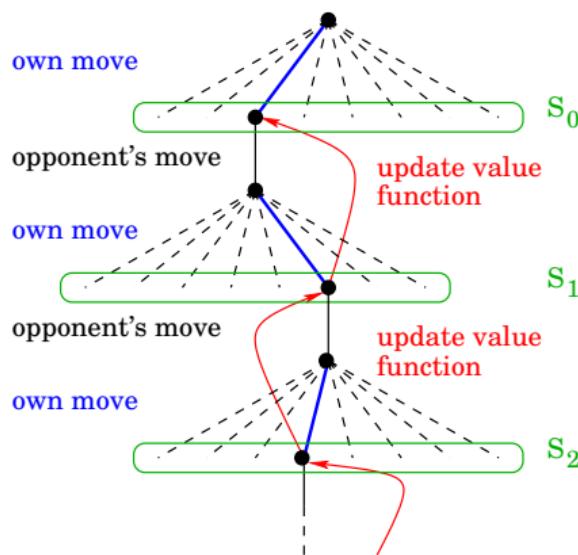
- Initial erhalten alle Zustände $s \in S$ einen Wert:
 - 3 \times 's in einer Zeile, einer Spalte oder einer Diagonalen erhalten den Wert $U(s) = 1$, da hier der Spielgewinn sicher ist.
 - 3 \circ 's in einer Zeile, einer Spalte oder einer Diagonalen erhalten den Wert $U(s) = 0$, da hier der Verlust sicher ist.
 - Alle anderen Zustände erhalten den Wert $U(s) = 1/2$, weil wir hier noch nichts über den Ausgang des Spiels wissen.
- Nun müssen sehr viele Spiele gegen einen oder mehrere Gegner gespielt werden.

- Um bei einem solchen Spiel einen Zug auszuwählen, betrachten wir die Werte der möglichen Nachfolgezustände.
 - Wir wählen dabei meistens den Zug, der in den Zustand s mit dem größten Wert $U(s)$ führt (greedy move).
 - Gelegentlich wählen wir allerdings auch einen Zug zufällig aus (Exploration).
 - Das Verhältnis von Greedy-Move und Exploration kann während des Trainings variieren.
- Nach einem Sieg werden die Werte $U(s)$ der Zustände s iterativ verbessert. Bei einem Greedy-Zug $s_t \rightarrow s_{t+1}$, nicht bei einem explorativen Zug, wird der Wert $U(s_t)$ in Richtung des Wertes $U(s_{t+1})$ angepasst:

$$U(s_t) := U(s_t) + \alpha \cdot [U(s_{t+1}) - U(s_t)] = (1 - \alpha) \cdot U(s_t) + \alpha \cdot U(s_{t+1})$$

Bei großen Zustandsräumen, also bei komplexen Spielen wie Schach oder Go, kann keine Hash-Tabelle für die Werte $U(s)$ genutzt werden, weil es zu viele Zustände gibt. Dann muss die Funktion U approximiert werden, wozu sich *Fourierreihen* oder *neuronale Netze* eignen.

Tic-Tac-Toe



Die Zustände in den grünen Bereichen, wo der Gegner am Zug ist, müssen bewertet werden.

- Diese Zustände müssen für den Agenten vielversprechend sein.
- Bewertungen dieser Zustände anpassen: $U(s_t) := U(s_t) + \alpha \cdot (U(s_{t+1}) - U(s_t))$

Einschub: Programm vorführen und besprechen.

- erreichte Zustände werden in einem `std::vector<State>` gespeichert.
- gewählter Diskontierungsfaktor ist eins
- für jeden Spieler eigene Value-Funktion

Q-Lernen: Bezeichne $Q(s, a)$ den Wert der Ausführung von Aktion a in Zustand s .
(Der Wert einer Aktion kann in unterschiedlichen Zuständen unterschiedlich sein.)

$$U(s) = \max_{a \in A(s)} Q(s, a)$$

Auf den ersten Blick ist das nur eine andere Form, den Nutzen eines Zustands zu berechnen bzw. zu definieren. Wenn die Q-Werte korrekt sind, muss gelten:

$$Q(s, a) = R(s) + \lambda \cdot \sum_{s'} P(s' | s, a) \cdot \max_{a' \in A(s')} Q(s', a')$$

Wie beim ADP-Agenten können wir diese Gleichung direkt als Aktualisierungs-gleichung für einen Iterationsprozess verwenden, der genaue Q-Werte berechnet, wenn ein geschätztes Modell gegeben ist. Das bedingt jedoch, dass auch ein Modell gelernt wird, weil die Gleichung $P(s' | s, a)$ verwendet.

Lernen einer Aktion-Nutzen-Funktion

Aber: Ein TD-Agent, der eine Q -Funktion lernt, braucht weder für das Lernen noch für die Aktionsauswahl ein Modell der Form $P(s' | s, a)$, es sind nur Q -Werte notwendig.

$$Q(s, a) := Q(s, a) + \alpha \cdot (R(s) + \gamma \cdot \max_{a' \in A(s')} Q(s', a') - Q(s, a))$$

```
function Q-LEARNING-TD-AGENT(s': state, r': double)
  ▷  $Q, N, s, a, r$  are global variables, and  $s \times a \rightarrow s'$  gives reward  $r'$ 
  if  $s$  is terminal state then
     $Q[s, \text{none}] := r'$ 
  if  $s$  is not null then
    increment  $N[s, a]$ 
     $Q[s, a] := Q[s, a] + \alpha(N[s, a]) \cdot (r + \gamma \cdot \max_{a' \in A(s')} Q(s', a') - Q(s, a))$ 
     $s := s', r := r'$ 
     $a := \arg \max_{a' \in A(s')} f(Q[s', a'], N[s', a'])$ 
  return  $a$ 
```

Hier wird wieder die Explorationsfunktion f genutzt und α als abfallende Funktion gewählt.

Schon bei Spielen wie 4-Gewinnt und Othello sind die Suchräume so groß, dass die Nutzenfunktion U oder die Aktion-Nutzen-Funktion Q nicht mehr als Tabelle im Speicher gehalten werden kann und daher nicht mehr exakt ermittelt werden kann.

Wir haben jetzt mehrfach gehört: Für so große Suchräume können die Funktionen durch Fourierreihen oder neuronale Netze approximiert werden.

Stimmt das denn eigentlich? Können wir die Funktionen denn überhaupt berechnen?
Haben wir so viel Zeit und Ressourcen?

Bei Tic-Tac-Toe können 5478 verschiedene Zustände⁽³³⁾ erreicht werden, bei 4-Gewinnt etwa $4,5 \cdot 10^{12}$ Zustände⁽³⁴⁾.

⁽³³⁾ <https://de.wikipedia.org/wiki/Tic-Tac-Toe>

⁽³⁴⁾ Edelkamp, Stefan; Kissmann, Peter: Symbolic classification of general two-player games. In: Annual Conference on Artificial Intelligence, Springer, 2008

Analyse bei Spielen

Tic-Tac-Toe: 5478 Zustände
bei 20% Exploration erreicht:

# Spiele	# Zustände
10.000	≈ 4.400
100.000	≈ 5.100
1.000.000	≈ 5.400
5.000.000	5474

4-Gewinnt: $4,5 \cdot 10^{12}$ Zustände
bei 20% Exploration erreicht:

# Spiele	# Zustände
100.000	$\approx 1.200.000$
1.000.000	$\approx 10.000.000$
2.000.000	$\approx 19.000.000$
10.000.000	$\approx 82.000.000$

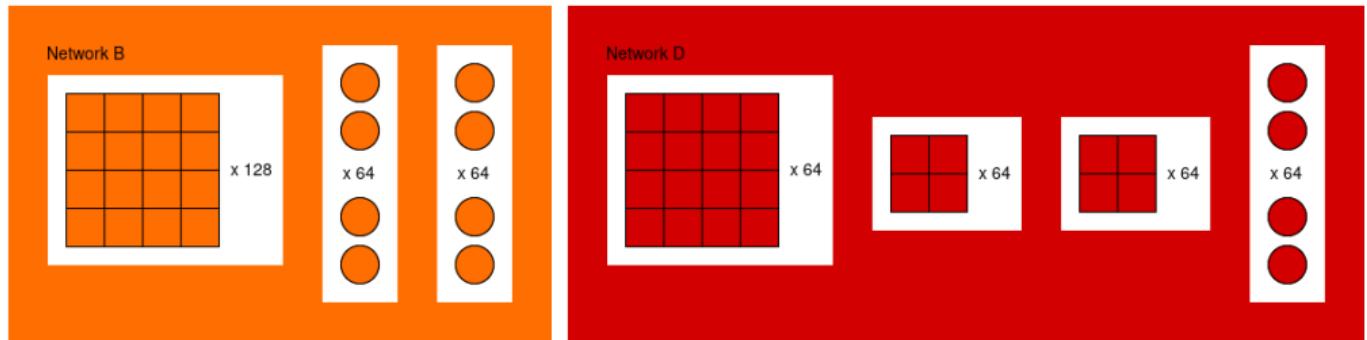
Annahme für 4-Gewinnt: 10^6 Spiele könnten in einer Sekunde gespielt und die Funktionswerte aller dabei erreichten Zustände berechnet werden, und es müssten $45 \cdot 10^{12}$ Spiele gespielt werden, damit jeder Zustand mindestens zehnmal bewertet wird. $\rightarrow 521$ Tage Laufzeit

Wir benötigen die künstlichen neuronalen Netze also nicht nur wegen des begrenzten Speicherplatzes als Approximation der Value-Funktionen, sondern auch um die fehlenden Werte der Value-Funktionen zu „interpolieren“, also als Interpolation für die Werte der Funktion, die aus Zeitmangel nicht berechnet werden konnten.

Problem: Welche Netze sind geeignet?

4-Gewinnt mittels Convolutional Neural Network⁽³⁵⁾:

- naheliegende Idee: Nutze 4×4 -Filter, um Reihen von vier Feldern bewerten zu können.



- Netzwerk B: ein Convolutional-Layer und zwei vollständig vernetzte Layer.
- Netzwerk D: ein Convolutional-Layer mit 4×4 -Grid, zwei Convolutional-Layer mit 2×2 -Grid und ein vollständig vernetzter Layer.

⁽³⁵⁾<https://codebox.net/pages/connect4>

Anstatt für große Suchräume die Funktionen durch Fourierreihen oder neuronale Netze zu approximieren, berechnen und speichern wir die Funktion nicht sondern ermitteln den Wert der Funktion durch eine Suche zur Laufzeit.

Time-Space Trade-Offs in a Pebble Game⁽³⁶⁾

Let $S(k, n)$ be the set of all directed acyclic graphs with n nodes where each node has indegree at most k . There exists a family of graphs $G_n \in S(2, n)$, $n = 1, 2, \dots$ and constants $c_1, c_2, c_3, c_2 < c_1$ such that for infinitely many n

- G_n can be pebbled with $c_1\sqrt{n}$ pebbles in n moves.
- G_n can also be pebbled with $c_2\sqrt{n}$ pebbles.
- Every strategy which pebbles G_n using only $c_2\sqrt{n}$ pebbles has at least $2^{c_3\sqrt{n}}$ moves.

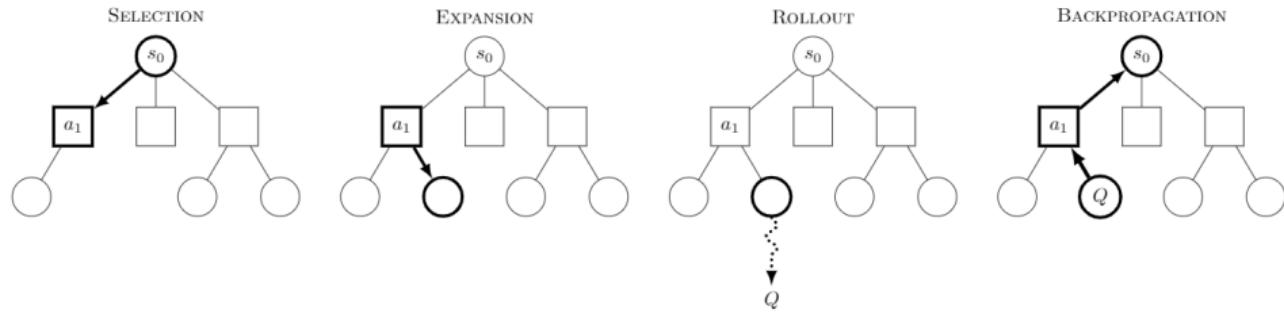
Thus even saving only a constant fraction of the pebbles already forces the time from linear to exponential.

Haben wir nicht genug Speicherplatz, um die Value-Funktion zu speichern, dann müssen wir Zeit investieren, eventuell sogar sehr viel Zeit.

⁽³⁶⁾Wolfgang J. Paul, Robert E. Tarjan. Proceedings of the 4th International Colloquium on Automata, Languages and Programming (ICALP), LNCS, volume 52, pages 365-369, Springer, 1977.
Wissensbasierte Systeme

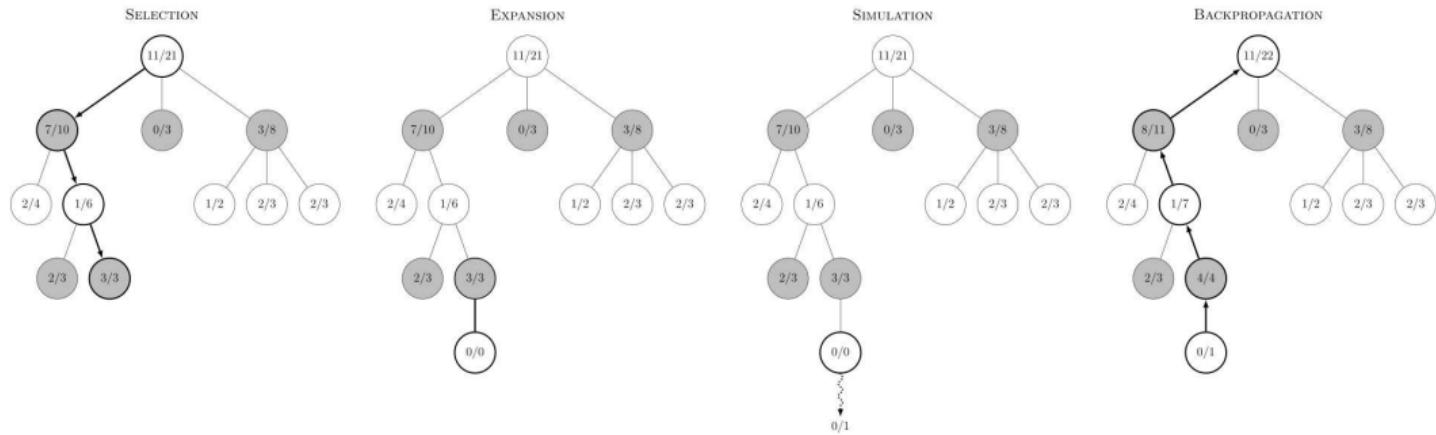
Idee der Monte-Carlo-Baumsuche:

- Wähle zunächst einen Knoten v im Suchbaum aus (SELECTION),
- führe einen noch nicht durchgeführten Zug auf diesen Zustand aus (EXPANSION),
- spiele das Spiel (z.B. zufällig) zu Ende (ROLLOUT oder SIMULATION)
- und bewerte anhand des Ausgangs des Spiels den Knoten v und seine Vorgäengerknoten neu. (BACKPROPAGATION)



Quelle: https://en.wikipedia.org/wiki/Monte_Carlo_tree_search

Monte-Carlo-Tree-Search



Quelle: https://en.wikipedia.org/wiki/Monte_Carlo_tree_search

Beim Backpropagation muss darauf geachtet werden, dass der Gewinn bzw. der Verlust immer abwechselnd verrechnet wird.

Dieser Zyklus aus Selection, Expansion, Roll-Out und Backpropagation muss sehr häufig wiederholt werden. Einfluss auf die Güte haben die Auswahl der Knoten und die Art, ein Spiel zu Ende zu spielen.

Problem: Es müssen riesige Suchbäume analysiert bzw. traversiert werden, d.h. die Laufzeit ist sehr hoch und inakzeptabel für die Spieler. Hier können parallele Algorithmen helfen, die Laufzeiten wesentlich zu verkürzen bzw. eine deutlich bessere Spielstärke zu erreichen.

Das Programm AlphaGo⁽³⁷⁾, dass auf Monte-Carlo-Tree-Search basiert, schlug im Jahr 2016 den damaligen Go-Weltmeister, was bis dahin noch keine künstliche Intelligenz geschafft hatte. Allerdings wurden dazu 1.920 CPUs und 280 GPUs genutzt.

weiteres Problem: Welche Knoten sollen ausgesucht werden? Die, die den höchsten Gewinn versprechen? Vielleicht wurden andere Knoten nur noch nicht ausreichend untersucht. → Exploration vs. exploitation

⁽³⁷⁾<https://en.wikipedia.org/wiki/AlphaGo>

Upper Confidence bound for Trees:

Quelle: wikipedia

Choose in each node of the game tree the move for which the expression

$$\frac{w_i}{n_i} + c \cdot \sqrt{\frac{\ln N_i}{n_i}}$$

has the highest value.

- w_i → number of wins for the node considered after the i -th move
- n_i → number of simulations for the node considered after the i -th move
- N_i → total number of simulations after the i -th move run by the parent node of the one considered
- $c = \sqrt{2}$ is the exploration parameter; in practice usually chosen empirically

The first component of the formula above corresponds to exploitation; it is high for moves with high average win ratio. The second component corresponds to exploration; it is high for moves with few simulations.

Einschub: Programme Tic-Tac-Toe und 4-Gewinnt vorführen und besprechen.

- KI ist etabliert:
 - Die meisten Informatik-Abteilungen haben KI-Professur.
 - Wissensbasierte Techniken werden in der Industrie breit genutzt.
- Relative Selbständigkeit anwendungsorientierter Teilbereiche:
 - Wissenssysteme (Diagnostik, Konfigurierung; Scheduling, Planung, Simulation; Wissensportale)
 - Sprachverarbeitung (hohe Qualität bei gesprochener Sprache; einfaches Verstehen geschriebener Texte - shallowparsing)
 - Bildverarbeitung
 - Robotik (Robo-Cup, Aibo, Marsroboter)
- Betonung logischer Grundlagen:
 - Hidden Markov Models
 - Bayessche Netze
 - logikbasierte Wissensrepräsentationen

- Schachprogramme haben Weltmeisterniveau erreicht.
- Natural Language Processing (NLP):
 - natürlichsprachliche Auskunftssysteme wie z.B. Reisebuchung
 - Spracheingabe, automatische Übersetzer
- erfolgreiche Expertensysteme in vielen Bereichen
 - Selbstdiagnose bei großen Maschinen
 - XUMA: eXpertensystem UMWeltgefährlichkeit von Altlasten
Das System soll Fachleute in Behörden und Ingenieurbüros bei der Bewertung von Altlasten und bei der Beurteilung ihrer Umweltgefährdung unterstützen.
 - PROPLANT: Auf Grundlage regionaler Witterung erfolgt eine schlagbezogene Pflanzenschutzberatung. Mittlerweile auch als internetbasierte Version verfügbar.
- automatische Planung und Scheduling in der Raumfahrt
- automatischer Autofahrer, Rasenmäher, Staubsauger
- Dokumentenanalyse: Belegleser
- Fuzzy Control: Fotoapparate, Waschmaschinen, Bremsanlagen

1 Übersicht

- Lernen durch Belohnung
- Planen

2 Geschichte und Anwendungen

- Turing-Test
- neuronale Netze
- Agenten
- Entscheidungsbäume
- Fallbasiertes Schließen
- Sequentielle Entscheidungsprobleme

3 Wissensrepräsentation

4 Zustandsraumsuche

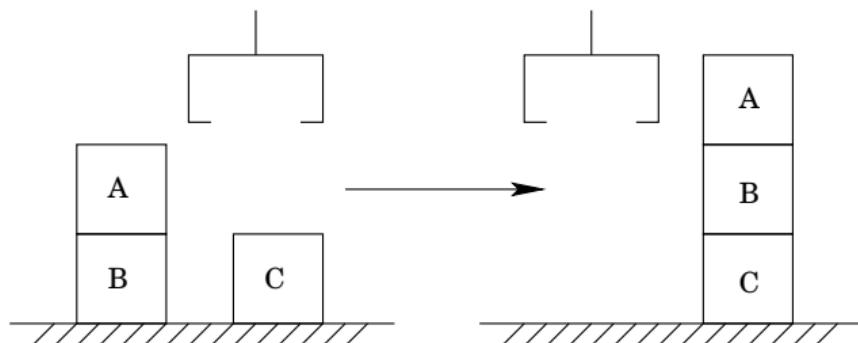
5 Aussagenlogik

6 Prädikatenlogik

7 Prolog

Ziel ist das Aufstellen einer Sequenz von Aktionen, die ausgehend von einem Startzustand einen gewünschten Zielzustand erreichen, unter Berücksichtigung aller Laufzeitbedingungen.

Beispiel: Blocks World



Plan:

```
unstack(A,B)
putdown(A)
pickup(B)
stack(B,C)
pickup(A)
stack(A,B)
```

Zustandsbeschreibung mittels Prädikaten:

- vorher: `onTable(B)`, `onTable(C)`, `upon(A,B)`, `empty()`, `clear(A)`, `clear(C)`
- nachher: `onTable(C)`, `upon(B,C)`, `upon(A,B)`, `empty()`, `clear(A)`

Regeln zur Erzeugung neuer Zustände:

- **pickup(x)**
 - PRECOND: `empty()` \wedge `clear(x)`
 - EFFECT: `hold(x)`
- **putdown(x)**
 - PRECOND: `hold(x)`
 - EFFECT: `empty()` \wedge `onTable(x)` \wedge `clear(x)`
- **stack(x,y)**
 - PRECOND: `hold(x)` \wedge `clear(y)`
 - EFFECT: `upon(x,y)` \wedge `empty()` \wedge `clear(x)`
- **unstack(x,y)**
 - PRECOND: `upon(x,y)` \wedge `clear(x)` \wedge `empty()`
 - EFFECT: `clear(y)` \wedge `hold(x)`

Hinweis: Kleine Buchstaben wie `x` und `y` bezeichnen Variablen, große Buchstaben wie `A` und `B` bezeichnen konkrete Objekte.

Was ist Planen?

- *Wissensbasis*: Definition von Operatoren.
- *Input*: Beschreibung von Start- und Zielsituation.
- *Output*: Der Plan, eine Sequenz von Aktionen.

Anwendungsbeispiele:

- Produktionsplanung
- Reiseplanung
- Spiele: Solitär, Rush Hour, 8-Puzzle usw.

Erzeugen eines Plans:

- Durchsuche einen Raum möglicher Aktionen so lange, bis eine Abfolge gefunden wird, die notwendig ist, um die betreffende Aufgabe zu bewältigen.
- Der Raum repräsentiert Zustände der Welt, die durch anwenden der Aktionen geändert werden.
- Planung verlässt sich auf Suchtechniken.
- Heuristiken können den Suchraum begrenzen.

Probleme:

- Die Beschreibung der Zustände der Welt ist sehr komplex.
- Wie können Pläne verallgemeinert werden?
- Systemwiederherstellung nach unerwarteten Planfehlschlägen?

- Im Laufe der Zeit ändern die Aktionen `unstack`, `stack`, `pickup` und `putdown` die Welt.
- Der Wahrheitswert von Aussagen wie `onTable(A)` ändert sich und ist abhängig von der aktuellen Situation.
- Prädikate, die Merkmale des Problembereichs beschreiben, erhalten als letztes Argument die Situation, auf die sich die Aussage bezieht.
 - Die Konstante `S0` bezeichnet die initiale Situation.
 - Es gibt ein spezielles Funktionssymbol `do`, das aus einer Aktion `a` und einer Situation `s` eine neue Situation `do(a, s)` bildet.
 - `do(stack(B, A), do(stack(A, C), do(unstack(B, C), S0)))` bezeichnet die Situation, die aus der initialen Situation durch Anwenden der Aktionsfolge `[unstack(B, C), stack(A, C), stack(B, A)]` entsteht.

Man nennt eine Situation auch Historie.

⁽³⁸⁾Beierle, Kern-Isbner: Methoden wissensbasierter Systeme. Vieweg, 2003.

- Ausführungsbedingungen: Die Formel $\text{Poss}(a, s)$ beschreibt, ob in Situation s die Aktion a ausgeführt werden kann.
 - $\text{Poss}(\text{stack}(x, y), s) \equiv \text{hold}(x, s) \wedge \text{clear}(y, s) \wedge x \neq y$
 - $\text{Poss}(\text{pickup}(x), s) \equiv \text{empty}(s) \wedge \text{clear}(x, s)$
- Effektaxiome spezifizieren die Veränderungen, die eine Aktion bewirkt.
 - $\text{Poss}(\text{stack}(x, y), s) \Rightarrow \text{upon}(x, y, \text{do}(\text{stack}(x, y), s))$
 - $\text{Poss}(\text{stack}(x, y), s) \Rightarrow \neg \text{clear}(y, \text{do}(\text{stack}(x, y), s))$
- Problem: In unserem Beispiel können wir nach der Ausführung von $\text{unstack}(A, B)$ in der initialen Situation nicht auf den Wahrheitswert von $\text{onTable}(B, \text{do}(\text{unstack}(A, B), S_0))$ schließen!
Die Operatoren beschreiben nur, was sich ändert, aber nicht das, was gleich bleibt! \rightarrow Frame-Problem⁽³⁹⁾⁽⁴⁰⁾

⁽³⁹⁾analogy: Frames of a movie, in which normally very little changes from one frame to the next.

⁽⁴⁰⁾siehe EAL: Die Übergangsbedingung U_1 beschreibt bei der Reduktion $\forall L \in NP : L \leq_p \text{SAT}$, den Übergang vom Zeitpunkt t nach $t + 1$ an der Stelle, wo sich der Schreib-Lesekopf befindet; die Übergangsbedingung U_2 beschreibt, dass sich der Bandinhalt auf allen anderen Positionen nicht ändert.

Rahmenproblem:

- Schwierigkeit, die Gültigkeit von Formeln auf die nachfolgende Situation zu übertragen.
- Lösung: Rahmenaxiome beschreiben genau, was durch eine Operation *nicht* verändert wird.
- Beispiel: `pickup(x)`
 - Zwei Blöcke, die durch die `pickup`-Operation nicht bewegt wurden, sind immer noch aufeinander:
$$\text{upon}(x, y, s) \wedge x \neq u \Rightarrow \text{upon}(x, y, \text{do}(\text{pickup}(u), s))$$
 - Ein Block befindet sich immer noch auf dem Tisch, wenn er durch die `pickup`-Operation nicht bewegt wurde:
$$\text{onTable}(x, s) \wedge x \neq u \Rightarrow \text{onTable}(x, \text{do}(\text{pickup}(u), s))$$
- Die Formulierung in Prädikatenlogik ist in der Praxis zu ineffizient: Sehr viele Rahmenaxiome beschreiben sehr viele (scheinbar redundante) Fakten, die erhalten bleiben.

Stanford Research Institute Problem Solver:

- Anfang der 1970er Jahre entwickelt, um die Probleme des Situationskalküls zu vermeiden, ohne jedoch die Logik als Basis von Zustandsrepräsentationen aufzugeben.
- Beeinflusste viele andere Planungssysteme, die in der Folgezeit entstanden.
- Beschreibe Zustände durch Mengen von Formeln, die wir Datenbasis nennen.
- Unique-Names-Assumption: Verschiedene Namen repräsentieren verschiedene Objekte.
- Closed-World-Assumption: Es werden nur positive Fakten gespeichert und alles, was nicht in der Datenbasis vorhanden ist, wird als falsch angesehen.

⁽⁴¹⁾ Beierle, Kern-Isbner: Methoden wissensbasierter Systeme. Vieweg, 2003.

Operatoren wie `unstack(x,y)` haben folgende Komponenten:

- Menge von Variablen: allquantifiziert
- Vorbedingungsteil: Konjunktion von positiven und negativen Literalen
 - PRECOND: `upon(x,y) ∧ clear(x) ∧ empty()`
- Effekte des Operators: positive und negative Fakten, die die entsprechenden Fakten in der Situation überschreiben.
 - ADD: `clear(y) ∧ hold(x)`
 - DELETE: `upon(x,y) ∧ clear(x) ∧ empty()`
- Die Ausführung eines Operators besteht aus zwei Schritten:
 - lösche alle Literale der DELETE-Liste aus der Datenbasis
 - füge alle Literale der ADD-Liste zu der Datenbasis hinzu
 - alle anderen Literale der Datenbasis bleiben erhalten
- Eine konkrete Anwendung eines Operators muss voll instanziert sein: Alle Variablen sind durch Konstanten substituiert.

Vorwärtssuche: (faktenbasiert)

- Gehe von der initialen Datenbasis aus und
- ändere die Datenbasis durch Operatoranwendungen,
- bis die Datenbasis die Zielbeschreibung erfüllt.

→ Ist in realistischen Anwendungsszenarien nicht praktikabel!

Rückwärtssuche: (zielorientiert)

- Gehe von dem zu erreichenden Ziel aus.
- Um einen Operator anwenden zu dürfen, müssen die Vorbedingungen erfüllt sein.
- Stelle die Vorbedingungen als Teilziel auf.

Mischung aus beiden Verfahren ist wünschenswert, um den Suchraum zu beschneiden
→ means-end-analysis

Mittel-Ziel-Analyse beim General Problem Solver⁽⁴²⁾:

- Ermittle syntaktische Unterschiede zwischen dem aktuellen Zustand und dem Zielzustand.
- Wähle einen dieser Unterschiede aus und suche den Operator, der diesen Unterschied reduzieren kann. Probleme:
 - Operator kann im aktuellen Zustand nicht angewendet werden. → erzeuge Teilziel, für den Operator angewendet werden kann
 - Operator erzeugt nicht den exakten Zielzustand. → Zwischenzustand wird neuer Startzustand für zweites Problem
- Hoffnung: GPS eignet sich als allgemeine, von Wissensdomäne unabhängige Architektur zum intelligenten Problemlösen, da nur die syntaktische Form von Zuständen untersucht wird.
- Leider: Es scheint nicht nur eine Heuristik zu geben, die sich erfolgreich auf alle Problemdomänen anwenden lässt.

⁽⁴²⁾ Newell, Shaw, Simon: Report on a general problem-solving program. Proceedings of the International Conference on Information Processing, 1959

Anmerkungen:

- Linearität:

Einem Plan liegt eine totale lineare zeitliche Ordnung zugrunde. Der Planungsalgorithmus nutzt diese Ordnung.

- Lösung des Rahmenproblems:

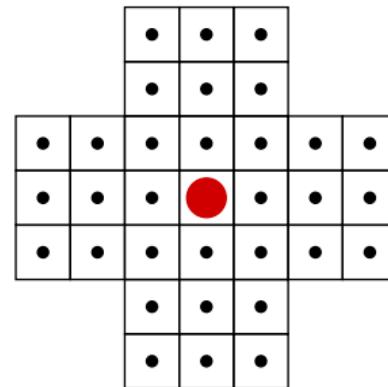
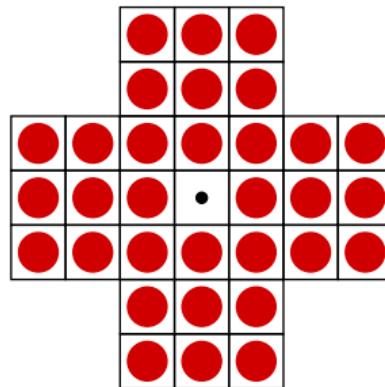
Jeder Operator ändert genau das, was als sein Effekt angegeben ist. Alle nicht angegebenen Fakten bleiben erhalten.

lässt sich nicht in Prädikatenlogik erster Stufe ausdrücken

Solitär: Gegeben ist ein (englisches) Spielbrett in Kreuzform mit 33 Löchern, in denen 32 Stäbchen stecken. Das Loch in der Mitte ist leer. Man muss nacheinander die Stäbchen entfernen, indem man sie in waagerechter oder senkrechter Richtung überspringt.



Am Ende muss ein Stäbchen in der Mitte übrigbleiben.



Übung 4. Schreiben Sie ein Programm, dass zu einem gegebenen Spielbrett eine Zugreihenfolge ermittelt. Welche Laufzeit ergibt sich?

Anmerkungen:

- Tiefensuche bzw. Backtracking liefert in diesem Fall eine optimale Lösung, weil alle Pläne die gleiche Länge haben. Pro Zug wird ein Feld weniger belegt. Bei anderen Spielen wie dem 15-Puzzle liefert Tiefensuche in der Regel keine optimale Lösung, allenfalls durch Zufall.
- Es ist kein Graph $G = (V, E)$ explizit gegeben, stattdessen werden die Zustände zur Laufzeit erzeugt, der „Graph“ bzw. der Suchraum wird also implizit aufgebaut. Daher können wir die Laufzeit nicht in Abhängigkeit von $|V|$ und $|E|$ angeben, sondern anhand der Tiefe des Baums und dem Verzweigungsgrad.
- Zustände müssen nicht in einer Hashtabelle oder ähnliches gespeichert werden. Normalerweise werden bei der Tiefensuche „Knoten“ markiert, damit Knoten nicht mehrfach besucht werden und somit Endlosschleifen vermieden werden. Da hier pro Zug ein Spielstein wegfällt, können sich Zustände nicht wiederholen.

Erkenne aussichtslose Spielsituation mittels Pagoda-Funktion pg :

- Sei P die Menge der zulässigen Positionen beim Solitär. Dann sei $\sigma : P \rightarrow \mathbb{R}$ eine Funktion, so dass für drei benachbarte Positionen a, b, c gilt: $\sigma(a) + \sigma(b) \geq \sigma(c)$
- Sei $B \subset P$ die Menge der aktuell belegten Positionen. Dann ist der Wert der Pagoda-Funktion definiert als

$$pg(B) := \sum_{b \in B} \sigma(b).$$

- Die Werte der Pagoda-Funktion sind monoton fallend im Laufe eines Spiels.



Die Suche kann abgebrochen werden, wenn der Wert der Pagoda-Funktion der aktuellen Spielsituation kleiner ist als der Wert für die Zielsituation.

Übung 5. Implementieren Sie folgende Pagoda-Funktion und vergleichen Sie die Laufzeiten Ihrer Implementierungen.

```
-1  0  -1
  1  1  1
-1  1  0  1  0  1  -1
  0  1  1  2  1  1  0
-1  1  0  1  0  1  -1
  1  1  1
-1  0  -1
```

Beispiel: Produktionsplanung⁽⁴³⁾ für zwei Produkte, zu deren Herstellung drei Maschinen A, B und C benötigt werden:

- maximale monatliche Laufzeiten der Maschinen:
A: 170 Stunden, B: 150 Stunden, C: 180 Stunden
- Produkt 1: eine Stunde Maschine A, eine Stunde Maschine B
- Produkt 2: zwei Stunden Maschine A, eine Stunde Maschine B und drei Stunden Maschine C

→ Maximiere Profit, wenn 300 Euro mit Produkt 1 und 500 Euro mit Produkt 2 verdient wird,

$$300 \cdot x + 500 \cdot y \rightarrow \max$$

ohne dabei die Maschinenlaufzeiten zu überschreiten:

$$\begin{aligned} x + 2 \cdot y &\leq 170 &\Leftrightarrow y &\leq \frac{170-x}{2} = 85 - x/2 \\ x + y &\leq 150 &\Leftrightarrow y &\leq 150 - x \\ 3 \cdot y &\leq 180 &\Leftrightarrow y &\leq \frac{180}{3} = 60 \end{aligned}$$

⁽⁴³⁾http://de.wikipedia.org/wiki/Lineare_Optimierung

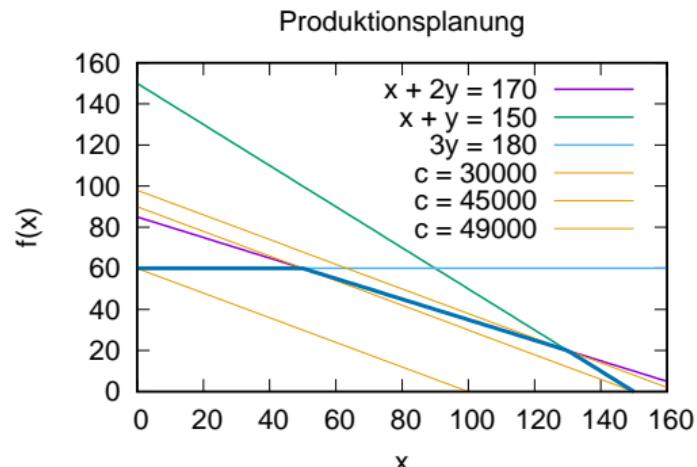
Wir ersetzen in den Ungleichungen das \leq durch ein $=$ und erhalten:

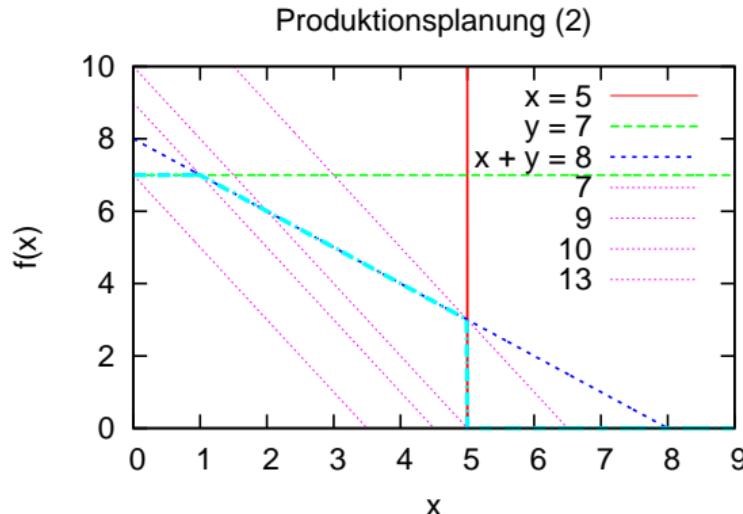
$$y = 85 - x/2 \quad y = 150 - x \quad y = 60$$

Betrachte zu maximierende Funktion $300 \cdot x + 500 \cdot y$ für konstante Zielwerte c :

$$300 \cdot x + 500 \cdot y = c \iff y = c/500 - 300/500 \cdot x$$

Wenn wir alle obigen Gleichungen in ein Diagramm eintragen, stellen wir fest, dass der optimale Wert auf einem Eckpunkt des resultierenden Polygons liegt:





Maximiere $2x_1 + x_2$

Randbedingungen:

$$0 \leq x_1 \leq 5$$

$$0 \leq x_2 \leq 7$$

$$0 \leq x_1 + x_2 \leq 8$$

Der optimale Wert liegt auf einem Eckpunkt des Polygons:

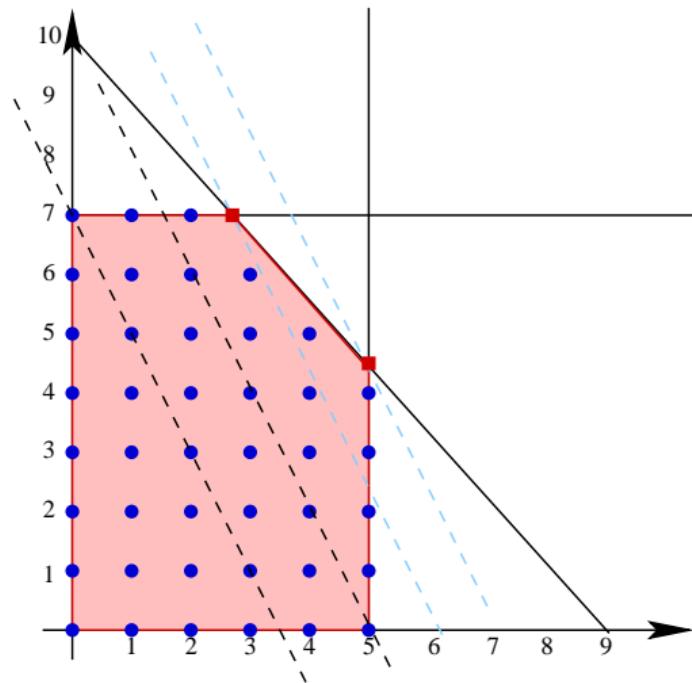
$$2x_1 + x_2 = 7 \iff x_2 = 7 - 2x_1$$

$$2x_1 + x_2 = 9 \iff x_2 = 9 - 2x_1$$

$$2x_1 + x_2 = 10 \iff x_2 = 10 - 2x_1$$

$$2x_1 + x_2 = 13 \iff x_2 = 13 - 2x_1$$

Verlangen wir, dass die Lösungen ganzzahlig sind, dann muss der optimale Wert nicht mehr auf einem Eckpunkt des Polygons liegen.



$$\text{Maximiere } 2x_1 + x_2$$

Randbedingungen:

$$x_1 \leq 5 \text{ und } x_1 \in \mathbb{N}$$

$$x_2 \leq 7 \text{ und } x_2 \in \mathbb{N}$$

$$10x_1 + 9x_2 \leq 90$$

Viele kombinatorische Probleme können als Integer Programm formuliert werden.

Beispiel: 0/1-Rucksackproblem mit Profiten p_1, \dots, p_n und den Gewichten w_1, \dots, w_n der n Objekte sowie dem nicht zu überschreitenden Gesamtgewicht G :

$$x_j = \begin{cases} 1 & \text{das Objekt } j \text{ ist im Rucksack} \\ 0 & \text{sonst} \end{cases}$$

Binary Integer Program: $x_j \in \{0, 1\} \forall j$

$$\begin{array}{ll} \max & \sum_{j=1}^n p_j x_j & \rightarrow \text{Profit über alle Objekte im Rucksack} \\ s.t. & \sum_{j=1}^n w_j x_j \leq G & \rightarrow \text{Gesamtgewicht nicht überschreiten} \end{array}$$

Beispiel: Vertex Cover für Graph $G = (V, E)$ berechnen:

$$x_v = \begin{cases} 1 & \text{der Knoten } v \text{ ist im Vertex Cover} \\ 0 & \text{sonst} \end{cases}$$

Binary Integer Program: $x_v \in \{0, 1\} \quad \forall v \in V$

- Minimiere die Anzahl der Knoten im Vertex Cover:

$$\min \sum_{v \in V} x_v$$

- Randbedingung: $x_u + x_v \geq 1 \quad \forall \{u, v\} \in E$

TSP mittels Integer Programming

Beispiel: Tourenplanung – Traveling Salesperson Problem für den Graph $G = (V, E, c)$ mit Kostenfunktion c :

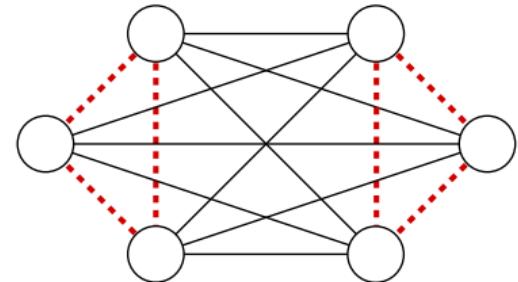
$$x_{ij} = \begin{cases} 1 & \text{die Kante } (i, j) \text{ ist in der Tour} \\ 0 & \text{sonst} \end{cases}$$

Binary Integer Program: $x_{ij} \in \{0, 1\} \quad \forall i, j$

$$\begin{array}{ll} \min & \sum_{i,j} c_{ij} x_{ij} \quad \rightarrow \text{Kosten über alle benutzten Kanten} \\ \text{s.t.} & \sum_j x_{ij} = 1 \quad \forall i \quad \rightarrow \text{Knoten } i \text{ genau einmal verlassen} \\ & \sum_i x_{ij} = 1 \quad \forall j \quad \rightarrow \text{Knoten } j \text{ genau einmal besuchen} \end{array}$$

Mit diesen Beschränkungen sind aber noch Teiltouren möglich, die keine Lösung des Problems beschreiben.

Wir fügen noch die Kurzzyklus-Ungleichungen oder auch Subtour-Eliminationsbedingungen ein.



Sei S eine nicht-leere echte Teilmenge von $\{1, \dots, n\}$.

- Jede Tour muss S mindestens einmal verlassen:

$$\sum_{i \in S} \sum_{j \notin S} x_{ij} \geq 1$$

- Oder: In jeder Tour kann es nicht mehr als $|S| - 1$ Kanten geben, die Knoten in S verbinden, sonst gibt es eine Teiltour:

$$\sum_{i \in S} \sum_{j \in S} x_{ij} \leq |S| - 1$$

Lineare Programmierung:

gegeben: Matrix $A \in \mathbb{R}^{m,n}$ und zwei Vektoren $b \in \mathbb{R}^m$ und $c \in \mathbb{R}^n$

zulässige Lösung: Vektor $x \in \mathbb{R}^n$, der lineare Bedingungen erfüllt:

$$\begin{aligned} a_{11}x_1 + a_{12}x_2 + \dots + a_{1n}x_n &\leq b_1 \\ a_{21}x_1 + a_{22}x_2 + \dots + a_{2n}x_n &\leq b_2 \\ \vdots &\vdots &\vdots &\vdots \\ a_{m1}x_1 + a_{m2}x_2 + \dots + a_{mn}x_n &\leq b_m \end{aligned}$$

Ziel: finde zulässigen Vektor x , der das Skalarprodukt

$$c^T x = c_1x_1 + \dots + c_nx_n$$

maximiert. Dieses Optimierungsproblem wird oft abkürzend als

$$\max\{c^T x \mid Ax \leq b, x \geq 0\}$$

geschrieben, wobei $Ax \leq b$ und $x \geq 0$ komponentenweise zu verstehen sind.

Überführen in Standardform:

- Minimieren statt Maximieren:

$$\min\{c^T x \mid Ax \leq b, x \geq 0\} \iff \max\{-c^T x \mid Ax \leq b, x \geq 0\}$$

- Größer-als statt Kleiner-als:

$$a_{i1}x_1 + \dots + a_{in}x_n \geq b_i \iff -a_{i1}x_1 - \dots - a_{in}x_n \leq -b_i$$

- Gleichheit statt Kleiner-gleich:

$$a_{i1}x_1 + \dots + a_{in}x_n = b_i \iff a_{i1}x_1 + \dots + a_{in}x_n \geq b_i \wedge a_{i1}x_1 + \dots + a_{in}x_n \leq b_i$$

- Nichtnegativität der Variablen: ersetze x_i durch $x'_i - x''_i$ mit $x'_i, x''_i \geq 0$

F. Gurski: Efficient Binary Linear Programming Formulations for Boolean Functions. Statistics, Optimization and Information Computing, Vol 2, 274 – 279, 2014.

- Every conjunction $x_1 \wedge x_2$ can be realized by introducing a new variable x_3 and three conditions

$$x_3 - x_1 \leq 0, \quad x_3 - x_2 \leq 0, \quad x_1 + x_2 - x_3 \leq 1$$

such that finally $x_3 = x_1 \wedge x_2$.

- Every n -ary disjunction $x_1 \vee x_2 \vee \dots \vee x_n$ can be realized by introducing a new variable x_{n+1} and $n+1$ conditions

$$x_1 - x_{n+1} \leq 0 \quad \dots \quad x_n - x_{n+1} \leq 0 \quad \text{and} \quad x_1 + x_2 + \dots + x_n - x_{n+1} \geq 0$$

such that finally $x_{n+1} = x_1 \vee x_2 \vee \dots \vee x_n$.

Die innere Punkte-Methode⁽⁴⁴⁾ oder die Ellipsoid-Methode liefern eine Lösung der Linearen Programmierung in polynomieller Zeit.

Probleme:

- Oft müssen die Variablen ganzzahlig sein.
 - Es können nicht 3.7 Flugzeuge gebaut werden.
 - Eine Maschine wird eingesetzt oder nicht.
- TSP: $\mathcal{O}(2^{|E|})$ viele Subtouren müssen durch Eliminationsbedingungen ausgeschlossen werden. (sind diese Subtouren überhaupt sinnvoll?)

Relaxation (Aufheben gewisser Einschränkungen):

- Lasse Ganzzahligkeitsbedingungen weg und berechne eine Lösung. Diese Lösung ist Schranke für eigentliches Problem.
- Nutze diese Schranke bei Branch-and-Bound-Verfahren, um den Suchraum zu begrenzen.

⁽⁴⁴⁾N.K. Karmarkar: A new polynomial-time algorithm for linear programming. Combinatorica, 1984.

Integer Programming

Mittels GLPK⁽⁴⁵⁾ (GNU Linear Programming Kit) können wir bspw. das n-Damen-Problem⁽⁴⁶⁾ lösen:

```
# size of the chess board
param n, integer, > 0, default 8;
# x[i,j] = 1 means a queen is placed in square [i,j]
var x{1..n, 1..n}, binary;

# at most one queen in each row, col, diagonal
subject to r{i in 1..n}: sum{j in 1..n} x[i,j] <= 1;
subject to c{j in 1..n}: sum{i in 1..n} x[i,j] <= 1;
s.t. diagl{k in 2..n..n-2}:
    sum{i in 1..n, j in 1..n: i-j == k} x[i,j] <= 1;
s.t. diagr{k in 3..n+n-1}:
    sum{i in 1..n, j in 1..n: i+j == k} x[i,j] <= 1;
```

⁽⁴⁵⁾<http://www.gnu.org/software/glpk/>

⁽⁴⁶⁾file:///usr/share/doc/glpk-utils/examples/queens.mod

```
# objective is to place as many queens as possible
maximize obj: sum{i in 1..n, j in 1..n} x[i,j];

# solve the problem
solve;

# print optimal solution
for {i in 1..n} {
    for {j in 1..n}
        printf " %s", if x[i,j] then "Q" else ".";
    printf("\n");
}

end;
# Written in GNU MathProg by Andrew Makhordin
```

Übung 6. Starten Sie obiges Programm mittels `glpsol -math queens.mod` für verschiedene Größen des Schachbretts.

GLPK enthält unter `/usr/share/doc/glpk-utils/examples/` Beispielprogramme für viele weitere Probleme:

- `sudoku.mod` ist ein Sudoku-Solver für das klassische Spiel der Größe 9×9 .
- `tsp.mod.gz` enthält Code zum Lösen des Travelling Salesperson Problems und einige kleinere Beispielgraphen.

Außerdem finden Sie unter `file:///usr/share/doc/glpk-doc/glpk.pdf` das Reference Manual zum GNU Linear Programming Kit sowie die Beschreibung `file:///usr/share/doc/glpk-doc/gmpl.pdf` der Modeling Language GNU MathProg.

Applegate, Bixby, Chvátal und Cook (1990): Beginn der Entwicklung des Programms Concorde, das an sämtlichen Lösungsrekorden der letzten Jahre beteiligt war.

Reinelt (1991): TSPLIB, Sammlung standardisierter Testinstanzen mit unterschiedlichem Schwierigkeitsgrad, anhand derer verschiedene Forschergruppen ihre Resultate vergleichen konnten.

Cook et al. (2006): beweisbar kürzeste Tour durch 85.900 Knoten eines Layoutproblems für integrierte Schaltkreise, was die bislang größte optimal gelöste TSPLIB-Instanz ist.⁽⁴⁷⁾

Für Instanzen mit mehreren Millionen Städten konnten sie mit Hilfe zusätzlicher Dekompositionstechniken Touren bestimmen, deren Länge beweisbar weniger als 1% vom Optimum entfernt liegt.

⁽⁴⁷⁾ Applegate, Bixby, Chvátal, Cook: The Traveling Salesman Problem. A Computational Study. Princeton University Press, 2007.

⁽⁴⁸⁾ http://de.wikipedia.org/wiki/Problem_des_Handlungsreisenden
Wissensbasierte Systeme

Ist es Zufall, dass der optimale Zielwert bei Linearer Programmierung auf einem Eckpunkt des Polygons liegt?

Beispiel:

$$\begin{aligned} & \text{maximiere} && 300 \cdot x_1 + 500 \cdot x_2 \\ & \text{s.t.} && x_1 + 2 \cdot x_2 \leq 170 \quad (1) \\ & && x_1 + x_2 \leq 150 \quad (2) \\ & && 3 \cdot x_2 \leq 180 \quad (3) \end{aligned}$$

Wie sieht eine obere Schranke für den Zielwert aus?

$$500 \cdot (2) \rightarrow 500x_1 + 500x_2 \leq 75000$$

$$300 \cdot (1) \rightarrow 300x_1 + 600x_2 \leq 51000$$

$$200 \cdot (1) + 100 \cdot (2) \rightarrow 300x_1 + 500x_2 \leq 49000$$

Die *Zielfunktion* kann also maximal den Wert 49000 annehmen!

Wir haben eine Linearkombination der Ungleichungen $Ax \leq b$ gebildet, die gerade der ursprünglichen Zielfunktion entspricht, oder zumindest (komponentenweise) größer als die ursprüngliche Zielfunktion ist, also:

$$\lambda^T \cdot A \geq c^T$$

Da wir eine möglichst kleine obere Schranke für das ursprüngliche Problem haben möchten, müssen wir die neue Zielfunktion $\lambda^T \cdot b$ minimieren!

ursprüngliches Problem:

$$\begin{aligned} & \text{maximiere} && c^T \cdot x \\ & \text{s.t.} && A \cdot x \leq b \\ & && x \geq 0 \end{aligned}$$

duales Problem:

$$\begin{aligned} & \text{minimiere} && \lambda^T \cdot b \\ & \text{s.t.} && \lambda^T \cdot A \geq c^T \\ & && \lambda \geq 0 \end{aligned}$$

Die beiden Zielwerte sind gleich, wenn beide LP's eine Lösung haben.

Beispiel:

<https://de.wikipedia.org/wiki/Simplex-Verfahren>

$$\begin{aligned} & \text{maximiere } z = 300 \cdot x_1 + 500 \cdot x_2 \\ \text{s.t. } & x_1 + 2 \cdot x_2 \leq 170 \\ & x_1 + x_2 \leq 150 \\ & 3 \cdot x_2 \leq 180 \\ & x_1 \geq 0, x_2 \geq 0 \end{aligned}$$

Zunächst überführen wir das gegebene lineare Programm durch Einführen von **Schlupf-Variablen** (engl. slack variables) in ein Gleichungssystem.

$$\begin{aligned} & \text{maximiere } z = 300 \cdot x_1 + 500 \cdot x_2 \\ \text{s.t. } & x_1 + 2 \cdot x_2 + y_A = 170 \\ & x_1 + x_2 + y_B = 150 \\ & 3 \cdot x_2 + y_C = 180 \\ & x_1 \geq 0, x_2 \geq 0, y_A \geq 0, y_B \geq 0, y_C \geq 0 \end{aligned}$$

Die Variablen des ursprünglichen Problems werden **Struktur-Variablen** genannt.

Das Gleichungssystem ist unterbestimmt, da wir zusätzlich zu den Strukturvariablen noch so viele Schlupfvariablen wie Gleichungen haben:

$$\begin{aligned} \text{maximiere } z &= 300 \cdot x_1 + 500 \cdot x_2 \\ \text{s.t. } x_1 + 2 \cdot x_2 + y_A &= 170 \\ x_1 + x_2 + y_B &= 150 \\ 3 \cdot x_2 + y_C &= 180 \end{aligned}$$

Wir schreiben dieses Gleichungssystem so um, dass die Schlupf-Variablen auf der linken Seite stehen.

$$\begin{aligned} z &= 0 + 300 \cdot x_1 + 500 \cdot x_2 \\ y_A &= 170 - x_1 - 2 \cdot x_2 \\ y_B &= 150 - x_1 - x_2 \\ y_C &= 180 - - 3 \cdot x_2 \end{aligned}$$

Eine initiale Lösung des Gleichungssystems kann man direkt ablesen: $x_1 = 0$, $x_2 = 0$, $y_A = 170$, $y_B = 150$ und $y_C = 180$. Die Variablen, die auf der linken Seite stehen und einen Wert ungleich Null haben, nennt man *Basis-Variablen*.

Diese gefundene Lösung versuchen wir schrittweise zu verbessern, indem die Werte der Variablen x_1 und x_2 erhöht werden.

zunächst: Wie groß darf x_1 bzw. x_2 werden, ohne dass eine Restriktion verletzt wird?

- x_1 : da $x_2 = 0$ ist, erhalten wir folgende Gleichungen

$$0 \leq y_A = 170 - 1 \cdot x_1 \Rightarrow x_1 \leq 170$$

$$0 \leq y_B = 150 - 1 \cdot x_1 \Rightarrow x_1 \leq 150$$

- x_2 : da $x_1 = 0$ ist, erhalten wir folgende Gleichungen

$$0 \leq y_A = 170 - 2 \cdot x_2 \Rightarrow x_2 \leq 170/2$$

$$0 \leq y_B = 150 - 1 \cdot x_2 \Rightarrow x_2 \leq 150$$

$$0 \leq y_C = 180 - 3 \cdot x_2 \Rightarrow x_2 \leq 180/3$$

Wert der Zielfunktion $z = 300 \cdot x_1 + 500 \cdot x_2$ ist 45.000 für $x_1 = 150$ bzw. 30.000 für $x_2 = 60$. Also tauschen wir x_1 und y_B . \rightarrow Greedy-Ansatz

Da der Wert y_B auf 0 sinkt, wenn wir $x_1 = 150$ setzen, schreiben wir die entsprechende Zeile um, so dass x_1 links steht

$$y_B = 150 - x_1 - x_2 \iff x_1 = 150 - y_B - x_2$$

und ersetzen x_1 in obigen Gleichungen:

$$\begin{aligned} z &= 0 + 300 \cdot (150 - y_B - x_2) + 500 \cdot x_2 \\ y_A &= 170 - 1 \cdot (150 - y_B - x_2) - 2 \cdot x_2 \\ y_C &= 180 - 0 \cdot (150 - y_B - x_2) - 3 \cdot x_2 \end{aligned}$$

Als neues Gleichungssystem erhalten wir:

$$\begin{aligned} z &= 45.000 - 300 \cdot y_B + 200 \cdot x_2 \\ y_A &= 20 + 1 \cdot y_B - 1 \cdot x_2 \\ x_1 &= 150 - 1 \cdot y_B - 1 \cdot x_2 \\ y_C &= 180 + 0 \cdot y_B - 3 \cdot x_2 \end{aligned}$$

Links stehen, wie immer, die Basisvariablen mit Wert ungleich 0.

Da die jetzige Zielfunktion noch einen positiven Koeffizienten enthält, kann die Lösung noch verbessert werden. Wir führen also einen weiteren Schritt durch, bei dem jetzt nur noch der Wert der Variablen x_2 geändert werden kann. Da $y_B = 0$ ist, gilt:

$$\begin{aligned}0 \leq y_A &= 20 - 1 \cdot x_2 \Rightarrow x_2 \leq 20 \\0 \leq x_1 &= 150 - 1 \cdot x_2 \Rightarrow x_2 \leq 150 \\0 \leq y_C &= 180 - 3 \cdot x_2 \Rightarrow x_2 \leq 180/3\end{aligned}$$

Wir setzen $x_2 = 20$ und y_A wird zu 0, daher schreiben wir die entsprechende Zeile um

$$y_A = 20 + 1 \cdot y_B - 1 \cdot x_2 \iff x_2 = 20 - y_A + y_B$$

und setzen dann x_2 in die Gleichungen ein:

$$\begin{aligned}z &= 45.000 - 300 \cdot y_B + 200 \cdot (20 - y_A + y_B) \\x_1 &= 150 - 1 \cdot y_B - 1 \cdot (20 - y_A + y_B) \\y_C &= 180 + 0 \cdot y_B - 3 \cdot (20 - y_A + y_B)\end{aligned}$$

Wir erhalten so schließlich:

$$\begin{aligned} z &= 49.000 - 100 \cdot y_B - 200 \cdot y_A \\ x_2 &= 20 + 1 \cdot y_B - 1 \cdot y_A \\ x_1 &= 130 - 2 \cdot y_B + 1 \cdot y_A \\ y_C &= 120 - 3 \cdot y_B + 3 \cdot y_A \end{aligned}$$

Auch hier stehen links wieder die Basisvariablen mit Wert ungleich Null. Es gibt also nach jedem Schritt andere Basisvariablen, wohingegen Struktur- und Schlupfvariablen immer gleich bleiben.

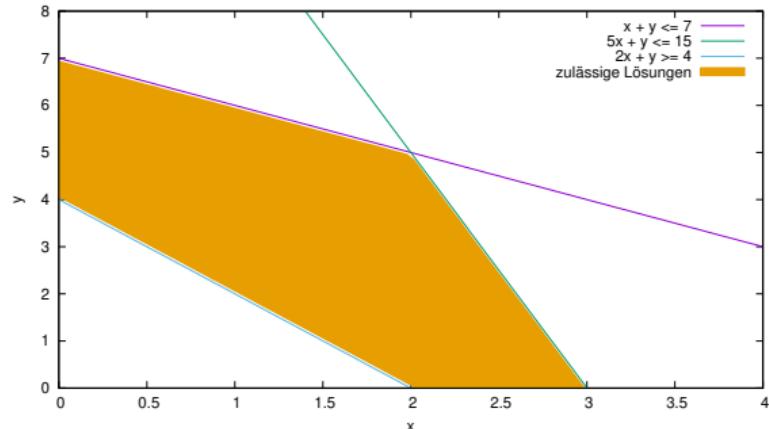
Da die Zielfunktion keine positiven Koeffizienten mehr enthält, ist eine optimale Lösung erreicht. Als Ergebnis stellen wir fest:

- Die Maschinen A und B sind voll ausgelastet ($y_A = y_B = 0$),
- der Profit beträgt 49.000,
- Maschine C könnte noch 120 Stunden genutzt werden.

Initiale Lösung für Simplex-Methode

Bisher sind wir davon ausgegangen, dass $x = y = 0$ eine gültige, initiale Lösung des Modells ist, die Strukturvariablen also alle auf Null gesetzt werden können. Wenn das aber nicht möglich ist, dann muss zunächst eine initiale Lösung bestimmt werden.

$$\begin{array}{lll} 3x & + & 2y \rightarrow \max \\ x & + & y \leq 7 \\ 5x & + & y \leq 15 \\ 2x & + & y \geq 4 \end{array}$$



Überführe das Modell in die Standardform,
füge eine neue Variable z ein und ändere
die Zielfunktion.

$$\begin{array}{lllll} & & - & z & \rightarrow \max \\ x & + & y & - & z \leq 7 \\ 5x & + & y & - & z \leq 15 \\ -2x & - & y & - & z \leq -4 \end{array}$$

Initiale Lösung für Simplex-Methode

Das modifizierte Modell hat immer eine Lösung, da z immer so groß gewählt werden kann, dass die linken Seiten der Ungleichungen beliebig klein werden und daher die Ungleichungen erfüllt sind. Hier erhalten wir als Lösung $x = 2$, $y = 0$ und $z = 0$.

$$\begin{array}{rcl} -z & \rightarrow & \max \\ x + y - z & \leq & 7 \\ 5x + y - z & \leq & 15 \\ -2x - y - z & \leq & -4 \end{array}$$

Das ursprüngliche Modell hat eine gültige Lösung genau dann wenn das modifizierte Modell eine Lösung mit $z = 0$ hat. Die Lösung des modifizierten Modells kann als initiale Lösung des ursprünglichen Modells genutzt werden.

$$\begin{array}{rcl} x + y \leq 7 & & 2 + 0 \leq 7 \\ 5x + y \leq 15 & & 10 + 0 \leq 15 \\ 2x + y \geq 4 & & 4 + 0 \geq 4 \end{array}$$

Anschließend arbeitet das Simplex-Verfahren so, wie es oben besprochen wurde.

Initiale Lösung für Simplex-Methode

Das lineare Programm inklusive Schlupfvariablen a, b, c hatte die folgende Form.

$$\begin{aligned} \text{maximiere } & z = 3 \cdot x + 2 \cdot y \\ \text{s.t. } & x + y + a = 7 \\ & 5x + y + b = 15 \\ & -2x - y + c = -4 \end{aligned}$$

Die berechnete initiale Lösung war $x = 2$ und $y = 0$. Um das Simplex-Verfahren mit dieser Lösung zu starten, gehen wir wie folgt vor. Zunächst setzen wir die Lösung ein und erhalten so initiale Werte für die Schlupfvariablen und für die Zielfunktion.

$$\begin{aligned} z &= 6 + 0 \\ 2 + 0 + a &= 7 \\ 10 + 0 + b &= 15 \\ -4 - 0 + c &= -4 \end{aligned}$$

Somit erhalten wir als Werte für die Schlupfvariablen $a = 5$, $b = 5$ und $c = 0$.

Initiale Lösung für Simplex-Methode

Um das Simplex-Verfahren zu starten, müssen wir die Gleichungen umstellen.

$$\begin{aligned}x + y + a &= 7 \\5x + y + b &= 15 \\-2x - y + c &= -4\end{aligned}$$

Die Variablen mit Wert ungleich Null müssen auf der linken Seite stehen, die anderen Variablen auf der rechten Seite. Also müssen x , a , b links stehen, y und c rechts.

$$\begin{aligned}a &= 7 - x - y \\b &= 15 - 5x - y \\-2x &= -4 + y - c\end{aligned}$$

Damit x nicht auf der rechten Seite steht, formen wir zunächst um

$$-2x = -4 + y - c \iff x = 2 - \frac{1}{2}y + \frac{1}{2}c$$

und setzen dann den Term für x in die ersten beiden Zeilen ein:

$$\begin{aligned}a &= 7 - (2 - \frac{1}{2}y + \frac{1}{2}c) - y = 5 + \frac{1}{2}y - \frac{1}{2}c - y = 5 - \frac{1}{2}y - \frac{1}{2}c \\b &= 15 - 5 \cdot (2 - \frac{1}{2}y + \frac{1}{2}c) - y = 15 - 10 + \frac{5}{2}y - \frac{5}{2}c - y = 5 + \frac{3}{2}y - \frac{5}{2}c\end{aligned}$$

Initiale Lösung für Simplex-Methode

Wenn wir auch bei der Zielfunktion den Term für x einsetzen, so erhalten wir schließlich

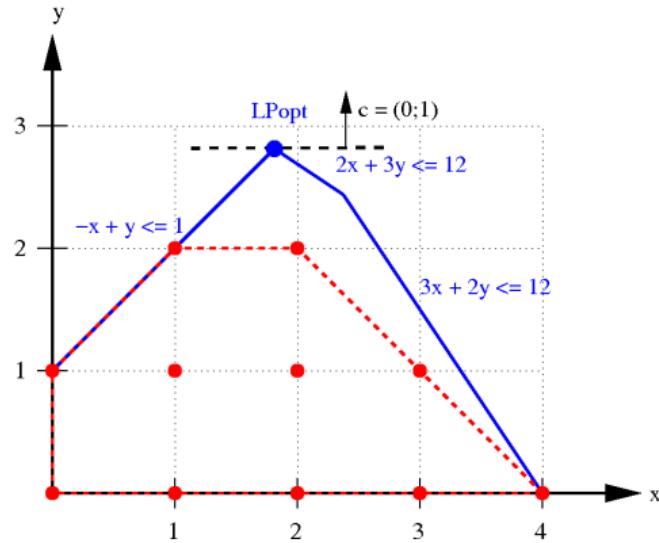
$$\begin{aligned} z &= 6 + \frac{1}{2}y + \frac{3}{2}c \\ a &= 5 - \frac{1}{2}y - \frac{1}{2}c \\ b &= 5 + \frac{3}{2}y - \frac{5}{2}c \\ x &= 2 - \frac{1}{2}y + \frac{1}{2}c \end{aligned}$$

wegen

$$\begin{aligned} z &= 3x + 2y \\ &= 3 \cdot (2 - \frac{1}{2}y + \frac{1}{2}c) + 2y \\ &= 6 - \frac{3}{2}y + \frac{3}{2}c + 2y \\ &= 6 + \frac{1}{2}y + \frac{3}{2}c \end{aligned}$$

Da eine Strukturvariable in der Zielfunktion ein positives Vorzeichen hat, wird das Simplex-Verfahren fortgesetzt.

Wir lösen zunächst das gegebene Problem mittels Simplex-Verfahren, lassen also die Ganzzahligkeitsbedingungen weg.



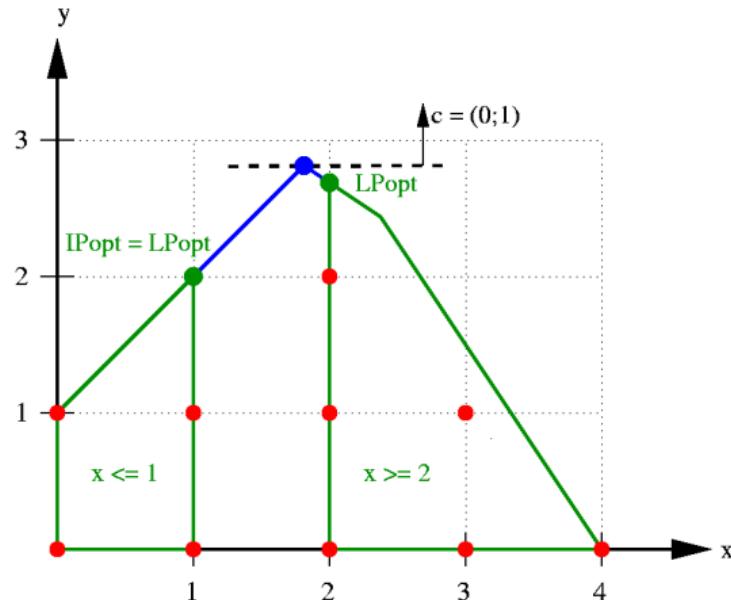
Die Lösung des relaxierten Problems liefert eine obere Schranke für den optimalen Wert der ganzzahligen Lösung, denn:

Jede zulässige Lösung des ganzzahligen Problems ist auch eine zulässige Lösung für das relaxierte Problem.

Der Wert der Lösung des relaxierten Problems wird *duale Schranke* genannt.

Quelle: https://de.wikipedia.org/wiki/Ganzzahlige_lineare_Optimierung

Für eine Basis- (und Struktur-) Variable, die die Ganzzahligkeitsbedingung verletzt, fügen wir eine obere bzw. untere Schranke als Bedingung hinzu. Wir erhalten so zwei Teilprobleme, die wir wieder mit dem Simplex-Verfahren lösen.



Quelle: https://de.wikipedia.org/wiki/Ganzzahlige_lineare_Optimierung

Bei jeder Verzweigung (branch) wird also der Wertebereich einer Variablen eingeschränkt. Dies wird solange wiederholt, bis eine ganzzahlige Lösung für das Teilproblem gefunden wurde. Dann endet in diesem Zweig die Suche.

Der optimale Wert ergibt sich aus dem Maximum der gefundenen, ganzzahligen Lösungen der Teilprobleme.

Eine bereits gefundene ganzzahlige Lösung eines der bearbeiteten Zweige ist eine untere Schranke des Problems und wird *primale Schranke* genannt.

Ist die Lösung des relaxierten Teilproblems schlechter als die primale Schranke, dann wird die Bearbeitung des aktuellen Zweigs abgebrochen (bound).

Gap (absolut): Differenz zwischen dualer und primaler Schranke.

Gap (relativ): Gap (absolut) dividiert durch primale Schranke.

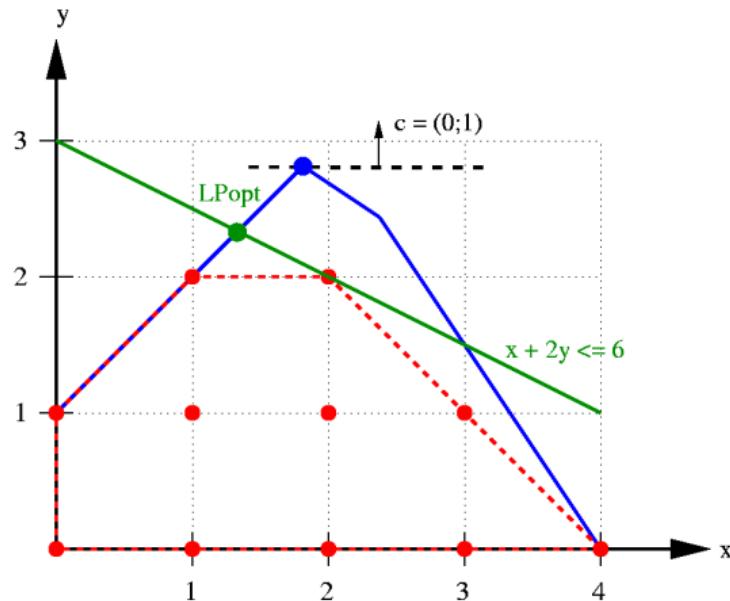
Die Laufzeit des Branch-and-Bound-Verfahrens ist in der Regel zu groß, weil zu wenig vom Suchbaum abgeschnitten wird.

Gute IP-Löser verbessern daher die duale Schranke mittels Schnittebenenverfahren.

Eine **Schnittebene** ist eine zusätzliche Ungleichung, die von allen zulässigen Punkten des IPs erfüllt wird, aber nicht von der aktuellen LP-Lösung. (siehe nächste Folie)

Wird die Ungleichung dem LP hinzugefügt, muss beim erneuten Lösen eine andere Lösung herauskommen.

Der Gap verkleinert sich, wenn eine kleinere, duale Schranke durch die Schnittebene (in der Grafik grün gezeichnet) gefunden wird.



Der Gap verkleinert sich auch dann, wenn eine bessere primale Schranke durch Lösen eines Teilproblems gefunden wird.

Lösen wir mittels Simplex-Verfahren das relaxierte lineare Programm aus dem obigen Bild.

$$\begin{aligned} & \text{maximiere } z = 1 \cdot x + 5 \cdot y \\ \text{s.t. } & -1 \cdot x + 1 \cdot y \leq 1 \\ & 3 \cdot x + 2 \cdot y \leq 12 \\ & 2 \cdot x + 3 \cdot y \leq 12 \\ & x \geq 0, y \geq 0 \end{aligned}$$

Nach Einfügen der Schlupfvariablen erhalten wir:

$$\begin{aligned} & \text{maximiere } z = 1 \cdot x + 5 \cdot y \\ \text{s.t. } & -1 \cdot x + 1 \cdot y + a = 1 \\ & 3 \cdot x + 2 \cdot y + b = 12 \\ & 2 \cdot x + 3 \cdot y + c = 12 \\ & x \geq 0, y \geq 0, a \geq 0, b \geq 0, c \geq 0 \end{aligned}$$

Als initiale Simplex-Tabelle ergibt sich:

$$\begin{array}{rclcl} z & = & 0 & + & 1 \cdot x & + & 5 \cdot y & (0) \\ a & = & 1 & + & 1 \cdot x & - & 1 \cdot y & (1) \\ b & = & 12 & - & 3 \cdot x & - & 2 \cdot y & (2) \\ c & = & 12 & - & 2 \cdot x & - & 3 \cdot y & (3) \end{array}$$

Eine initiale Lösung ergibt sich für $x = 0$ und $y = 0$. Anhand der Nebenbedingungen ermitteln wir, wie groß y werden darf:

$$\begin{array}{rclcl} 0 \leq a & = & 1 - 1 \cdot y & \Rightarrow & y \leq 1 \\ 0 \leq b & = & 12 - 2 \cdot y & \Rightarrow & y \leq 6 \\ 0 \leq c & = & 12 - 3 \cdot y & \Rightarrow & y \leq 4 \end{array}$$

Wir setzen $y = 1$, formen Gleichung (1) nach y um, setzen $y = 1 + x - a$ in (0), (2) und (3) ein und erhalten:

$$\begin{aligned} z &= 0 + 1 \cdot x + 5 \cdot (1 + x - a) \\ &= 5 + 6x - 5a \quad (0') \\ y &= 1 + 1 \cdot x - 1 \cdot a \\ &= 1 + x - a \quad (1') \\ b &= 12 - 3 \cdot x - 2 \cdot (1 + x - a) \\ &= 10 - 5x + 2a \quad (2') \\ c &= 12 - 2 \cdot x - 3 \cdot (1 + x - a) \\ &= 9 - 5x + 3a \quad (3') \end{aligned}$$

Wir ermitteln nun, wie groß x werden darf:

$$\begin{aligned} 0 \leq y &= 1 + 1 \cdot x \Rightarrow x \leq \infty \\ 0 \leq b &= 10 - 5 \cdot x \Rightarrow x \leq 2 \\ 0 \leq c &= 9 - 5 \cdot x \Rightarrow x \leq \frac{9}{5} \end{aligned}$$

Wir setzen $x = 9/5$, formen Gleichung (3') nach x um, setzen $x = 9/5 + 3/5a - 1/5c$ in (0'), (1') und (2') ein und erhalten:

$$\begin{aligned} z &= 5 + 6 \cdot (9/5 + 3/5a - 1/5c) - 5 \cdot a \\ &= 15 \frac{4}{5} - 1 \frac{2}{5}a - 1 \frac{1}{5}c \\ y &= 1 + 1 \cdot (9/5 + 3/5a - 1/5c) - 1 \cdot a \\ &= 2 \frac{4}{5} - 2/5a - 1/5c \\ b &= 10 - 5 \cdot (9/5 + 3/5a - 1/5c) + 2 \cdot a \\ &= 1 - 3a + c \\ x &= 9/5 + 3/5 \cdot a - 1/5 \cdot c \\ &= 1 \frac{4}{5} + 3/5a - 1/5c \end{aligned}$$

Um Gomory-Cuts zu berechnen, trennen wir den ganzzahligen Teil vom nicht-ganzzahligen Teil einer der obigen Gleichungen:

$$y = 2 \frac{4}{5} - 2/5a - 1/5c \iff y + 2/5a + 1/5c = 2 + 4/5$$

Da y ganzzahlig ist und $y \geq 0$, $a \geq 0$, $b \geq 0$ gilt, erhalten wir:

$$y \leq 2 \quad \text{und} \quad 2/5a + 1/5c \geq 4/5$$

Die letzte Zeile ist ein Gomory-Cut.

$$\frac{2}{5}a + \frac{1}{5}c \geq \frac{4}{5} \iff 2a + 1c \geq 4$$

Wollen wir diesen Cut in unser Bild einzeichnen, müssen wir die zusätzliche Nebenbedingung bezüglich der x - und y -Werte umrechnen:

$$\begin{aligned} -x + 1y + a &= 1 & \iff & -2x + 2y + 2a = 2 \\ 2x + 3y + c &= 12 \end{aligned}$$

Wenn wir diese Gleichungen addieren und den Gomory-Cut einsetzen, erhalten wir:

$$5y + 2a + c = 14 \iff 5y \leq 10 \iff y \leq 2$$

Durch diesen Cut schneiden wir die aktuelle Lösung des LP-Problems ab, behalten aber alle ganzzahligen Lösungen.

Übung 7. Lösen Sie das folgende lineare Programm mittels des Simplex-Verfahrens und bestimmen Sie einen Gomory-Cut.

$$\begin{array}{ll} \text{maximiere} & y \\ \text{s.t.} & -x + y \leq 1 \\ & x + 2y \leq 10 \end{array}$$

Zeichnen Sie den Gomory-Cut sowie die obigen Geraden in ein Koordinatensystem ein.

Anmerkung: Bei ganzzahliger Programmierung können die Schlupfvariablen auch ganzzahlig gewählt werden. Betrachten wir dazu rationale Koeffizienten wie im folgenden Beispiel:

$$\frac{1}{3}x + \frac{2}{5}y \leq \frac{5}{2} \quad (1)$$

$$\frac{1}{4}x - \frac{2}{3}y \leq \frac{6}{5} \quad (2)$$

Diese Gleichungen können äquivalent umformuliert werden:

$$5x + 6y \leq \frac{75}{2} = 37,5 \quad (1) \cdot 3 \cdot 5$$

$$3x - 8y \leq \frac{72}{5} = 14,4 \quad (2) \cdot 4 \cdot 3$$

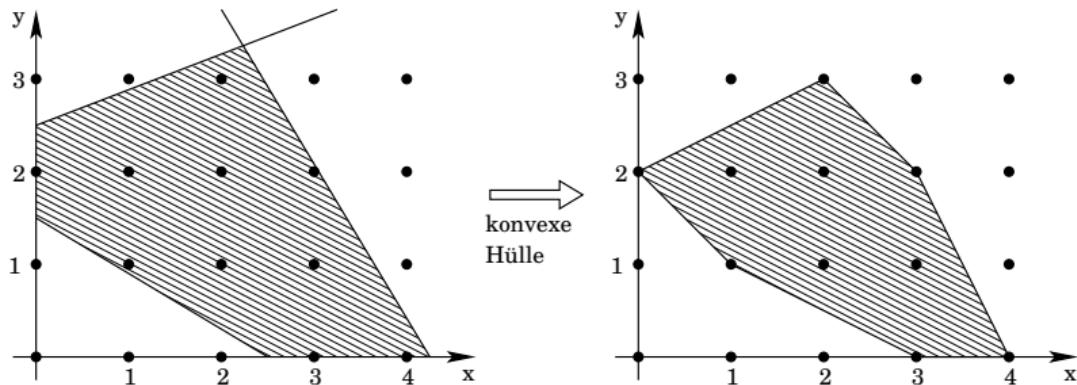
Weil x und y ganzzahlig sind und $x \geq 0, y \geq 0$ gilt, können wir weiter vereinfachen und erhalten ganzzahlige Schlupfvariablen:

$$5x + 6y \leq \lfloor 37,5 \rfloor = 37 \quad \Rightarrow \quad 5x + 6y + a = 37$$

$$3x - 8y \leq \lfloor 14,4 \rfloor = 14 \quad \Rightarrow \quad 3x - 8y + b = 14$$

Integer Programming: Schnittebenen

Werden geeignete Schnittebenen gefunden, dann kann ein Integer-Programm auch ohne Branch-and-Bound gelöst werden:



Besonders effektiv sind daher Schnittebenen, die möglichst weit oben im Baum, also möglichst nahe bei der Wurzel angewendet werden können.

→ Alle MIP-Solver nutzen eine Vorverarbeitung (presolve).

Cover-Cuts werden auch Knapsack-Cuts genannt. Sei $N \subseteq \{1, \dots, n\}$ und

$$\sum_{j \in N} a_j \cdot x_j \leq b; \quad x_i \in \{0, 1\}; \quad a_i > 0; \quad b > 0$$

eine Randbedingung des Modells. Dann ist $C \subseteq N$ ein *Cover*, wenn $\sum_{j \in C} a_j > b$ gilt.

→ Füge die Schnittebene $\sum_{j \in C} x_j \leq |C| - 1$ dem Modell hinzu.

Beispiel: Für die Randbedingung $4x_1 + 2x_2 + 3x_3 + 6x_4 \leq 8$ mit binären Variablen $x_1, x_2, x_3, x_4 \in \{0, 1\}$ erhalten wir unter anderem folgende Cover-Cuts:

$$3 + 6 > 8 \quad \rightarrow \quad x_3 + x_4 \leq 1$$

$$4 + 6 > 8 \quad \rightarrow \quad x_1 + x_4 \leq 1$$

$$4 + 2 + 3 > 8 \quad \rightarrow \quad x_1 + x_2 + x_3 \leq 2$$

Zwei binäre Variablen sind *inkompatibel*, wenn nicht beide gleichzeitig den Wert eins einnehmen können.

$$x + y \leq 1 \quad \rightarrow \quad x \text{ und } y \text{ sind inkompatibel}$$

Eine *Clique* C ist eine Menge von paarweise inkompatiblen Variablen.

→ Füge die Schnittebene $\sum_{j \in C} x_j \leq 1$ dem Modell hinzu.

Beispiel: Die binären Variablen der folgenden Randbedingungen bilden eine Clique.

$$x + y \leq 1 \quad x + z \leq 1 \quad y + z \leq 1$$

Füge die Schnittebene $x + y + z \leq 1$ dem Modell hinzu.

Bei großen oder generierten Modellen können unnötige bzw. redundante Bedingungen vorkommen, die zunächst entfernt werden:

- Eine Bedingung wie $x + y \leq 2$ für zwei binäre Variablen stellt keine Einschränkung dar und kann entfernt werden.
- Beschreiben Randbedingungen das Gleiche wie bei $x + y \geq 7$ und $2x + 2y \geq 14$, dann können alle bis auf eine aus dem Modell entfernt werden.
- Bei einer Randbedingung wie $7x_1 + 3x_2 + 5x_3 \geq 13$ und binären Variablen $x_1, x_2, x_3 \in \{0, 1\}$ muss für eine gültige Lösung $x_1 = x_2 = x_3 = 1$ gelten.

→ Weniger Randbedingungen und Variablen bedeuten weniger Rechenaufwand und Speicherbedarf zur Lösung des Modells.

Wird eine Randbedingung durch eine andere *dominiert*, dann kann die dominierte Bedingung aus dem Modell entfernt werden. Von den Bedingungen

$$\begin{array}{rcl} 3x_1 & + & 2x_2 & + & 5x_3 & \leq & 14 & (\text{Zeile } i) \\ 4x_1 & + & 2x_2 & + & 7x_3 & \leq & 13 & (\text{Zeile } j) \end{array}$$

mit $b_i \geq b_j$ und $a_{ik} \leq a_{jk}$ für alle $1 \leq k \leq n$ kann Zeile i entfernt werden.

Weitere Schritte der Vorverarbeitung ergeben sich oft durch Auf- bzw. Abrunden von nicht ganzzahligen Werten, denn ganzzahlige Vielfache von ganzzahligen Werten sind ebenfalls ganzzahlig:

- Eine nicht-ganzzahlige Grenze einer ganzzahligen Variablen kann abgeschnitten werden: Für $x \in \mathbb{N}_0$ kann $x \leq 2,5$ durch $x \leq \lfloor 2,5 \rfloor = 2$ ersetzt werden.
- Randbedingung $3x_1 + 6x_2 + 3x_3 \leq 8$ mit ganzzahligen Variablen $x_1, x_2, x_3 \in \mathbb{N}_0$ kann zu $3x_1 + 6x_2 + 3x_3 \leq 6$ modifiziert werden, da 8 kein Vielfaches von 3 ist.

Da große numerische Werte beim Rechnen oft Probleme machen, kann der letzte Schritt verbessert werden, indem durch den gemeinsamen Teiler der Koeffizienten der linken Seite geteilt und dann die rechte Seite abgerundet wird: Wegen

$$3x_1 + 6x_2 + 3x_3 \leq 8 \iff \frac{3}{3}x_1 + \frac{6}{3}x_2 + \frac{3}{3}x_3 \leq \frac{8}{3}$$

können wir die Randbedingung durch $x_1 + 2x_2 + x_3 \leq \lfloor 8/3 \rfloor = 2$ ersetzen.

Durch den letzten obigen Schritt können sich Randbedingungen ergeben, durch die einige Variablen eindeutig bestimmt sind:

Für ganzzahlige Variablen $x_1, x_2 \in \mathbb{N}_0$ ist die Randbedingung $2x_1 + 2x_2 \leq 1$ äquivalent zu $x_1 + x_2 \leq 1/2$ und daher gilt $x_1 + x_2 \leq \lfloor 1/2 \rfloor = 0$.

Also gilt $x_1 = x_2 = 0$ für eine zulässige Lösung.

Sinn der „Verbesserungen“ des Modells durch Schnittebenen: Je weniger sich die Lösungsräume der relaxierten und der ganzzahligen Modelle unterscheiden, umso weniger Verzweigungen sind beim Branch-and-Bound nötig.

Der GLPK-Solver kennt außer den Cover- und Clique-Cuts außerdem noch Gomory-Mixed-Integer- und Mixed-Integer-Rounding-Cuts. Der CBC-Solver kennt noch weitere Cuts wie Flow-Cover-, Split- und Capacity-Cuts.

Für eine Randbedingung wie $x - y \leq b$ mit $x \in \mathbb{N}_0$ und $y \in \mathbb{R}_0^+$ fügen wir die Schnittebene $x - \frac{1}{1-f} \cdot y \leq \lfloor b \rfloor$ in das Modell ein, wobei $f := b - \lfloor b \rfloor$ der Nachkommateil von b ist.

Beispiel: Gegeben sei die Randbedingung $x - y \leq 2,5$ mit $x \in \mathbb{N}_0$, $y \in \mathbb{R}_0^+$.

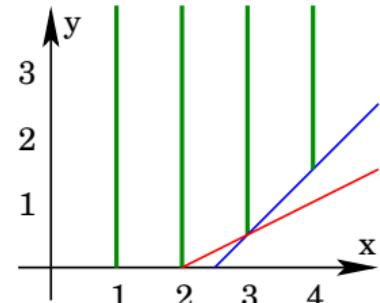
Dann gilt $f = 2,5 - \lfloor 2,5 \rfloor = 0,5$ sowie $\frac{1}{1-f} = \frac{1}{0,5} = 2$ und wir erhalten die Schnittebene $x - 2y \leq \lfloor 2,5 \rfloor = 2$.

Um zu sehen, dass eine solche Schnittebene gültig ist, betrachten wir die zwei Fälle $x \leq \lfloor b \rfloor$ und $x \geq \lfloor b \rfloor + 1$.

1. Fall: $x \leq \lfloor b \rfloor$

Offensichtlich gilt $-\frac{1}{1-f} \cdot y \leq 0$. Addieren wir die beiden Ungleichungen, so erhalten wir die zu zeigende Aussage:

$$x - \frac{1}{1-f} \cdot y \leq \lfloor b \rfloor + 0 = \lfloor b \rfloor$$



Pre-Solving im MIP-Solver

Fortsetzung: $x - y \leq b$ mit $x \in \mathbb{N}_0$ und $y \in \mathbb{R}_0^+$ ergibt Schnittebene $x - \frac{1}{1-f} \cdot y \leq \lfloor b \rfloor$.

2. Fall: $x \geq \lfloor b \rfloor + 1 \iff -x \leq -\lfloor b \rfloor - 1$

Multiplizieren wir diese Ungleichung mit $\frac{f}{1-f}$, so erhalten wir:

$$-\frac{f}{1-f} \cdot x \leq \frac{f}{1-f} \cdot (-\lfloor b \rfloor - 1)$$

Außerdem multiplizieren wir die ursprüngliche Randbedingung mit $\frac{1}{1-f}$ und erhalten:

$$\frac{1}{1-f} \cdot (x - y) \leq \frac{1}{1-f} \cdot b$$

Addieren wir beide Ungleichungen, so erhalten wir:

$$-\frac{f}{1-f} \cdot x + \frac{1}{1-f} \cdot (x - y) \leq \frac{f}{1-f} \cdot (-\lfloor b \rfloor - 1) + \frac{1}{1-f} \cdot b$$

Wir erhalten die zu zeigende Aussage, wenn wir $b = f + \lfloor b \rfloor$ einsetzen.

```
#include <glpk.h>
.....
glp_prob *lp = glp_create_prob();
glp_read_mps(lp, GLP_MPS_FILE, 0, "filename");
glp_term_out(GLP_ON);

glp_adv_basis(lp, 0);
int rc = glp_simplex(lp, 0);
if (rc != 0 || glp_get_status(lp) != GLP_OPT) {
    cout << "error" << endl; return 1;
}
cout << "lp: " << glp_get_obj_val(lp) << endl;

rc = glp_intopt(lp, 0);
if (rc == 0)
    cout << "opt: " << glp_mip_obj_val(lp) << endl;
else cout "error" << endl;
glp_delete_prob(lp);
```

MIPLIB 2003	http://miplib2010.zib.de/miplib2003/index.php
MIPLIB 2010	http://miplib2010.zib.de
MIPLIB 2017	http://miplib.zib.de

- electronically available library of both pure and mixed integer programs
- has become a standard test set used to compare the performance of mixed integer optimizers

Übung 8. Starten Sie glpsol für verschiedene Instanzen der MIPLIB. Testen Sie verschiedene Heuristiken für Node-Selection und Branching.

Auszug aus glpsol -help:

```
--first    branch: first integer variable
--last     branch: last integer variable
--mostf    branch: most fractional variable
--drtom    branch: heuristic by Driebeck and Tomlin(*)
--pcost    branch: hybrid pseudocost heuristic
```

Auszug aus glpsol -help: (Fortsetzung)

```
--dfs      backtrack: depth first search
--bfs      backtrack: breadth first search
--bestp    backtrack: best projection heuristic
--bestb    backtrack: best local bound(*)  
  
--gomory  generate Gomory's mixed integer cuts
--mir     generate Mixed Integer Rounding cuts
--cover   generate mixed cover cuts
--clique  generate clique cuts
--cuts    generate all cuts above
```

Branching Rules: Let x_i be a variable with fractional LP value.

- *Most Fractional Branching* choose the variable with fractional part closest to 0.5
 - $score(x_i) := 0.5 - |\tilde{x}_i - \lfloor \tilde{x}_i \rfloor - 0.5|$
 - Beispiel: $score(7.9) = 0.1$, $score(3.6) = 0.4$
 - Wähle x_j mit $score(x_j)$ maximal.
- *Least Fractional Branching* choose the variable that is almost an integer
 - $score(x_i) := |\tilde{x}_i - \lfloor \tilde{x}_i \rfloor - 0.5|$
 - Beispiel: $score(7.9) = 0.4$, $score(3.6) = 0.1$
 - Wähle x_j mit $score(x_j)$ maximal.
- *Full Strong Branching* test which of the fractional candidates gives the best progress
 - Δ_l change in objective value of left branch on x_i
 - Δ_r change in objective value of right branch on x_i
 - $score(x_i) := (1 - \mu) \cdot \min\{\Delta_l, \Delta_r\} + \mu \cdot \max\{\Delta_l, \Delta_r\}$
- *Pseudo-Cost Branching* und weitere ...

```
#include <iostream>
#include <list>
#include <cmath>
#include <cfloat>
#include <glpk.h>
#include <unistd.h>

using namespace std;

const double _eps = 1e-8;

list<int> getFractionalVariables(glp_prob *p);
int getBranchVariable(glp_prob *p);
double getScore(glp_prob *p, int var);
pair<glp_prob *, glp_prob *> getBranches(glp_prob *job, int i);
```

```
int getBranchVariable(glp_prob *p) {
    double val = 0.0;
    int var = -1;
    list<int>::iterator it;
    list<int> vars = getFractionalVariables(p);

    for (it = vars.begin(); it != vars.end(); it++) {
        double score = getScore(p, *it);

        if (score > val) {
            val = score;
            var = *it;
        }
    }
    return var;
}
```

```
list<int> getFractionalVariables(glp_prob *p) {
    list<int> vars;
    int cols = glp_get_num_cols(p);

    for (int i = 1; i <= cols; i++) {
        int knd = glp_get_col_kind(p, i);

        if (glp_get_col_stat(p, i) == GLP_BS &&
            (knd == GLP_IV || knd == GLP_BV)) {
            double xi = glp_get_col_prim(p, i);
            double rVal = round(xi);
            double diff = fabs(xi - rVal);

            if (diff >= _eps) vars.push_back(i);
        }
    }
    return vars;
}
```

`glp_get_num_cols(glp_prob *P)` returns the current number of columns in the specified problem object.

`glp_get_col_kind(glp_prob *P, int j)` returns the kind of j-th column (structural variable) as follows:

- `GLP_IV` – integer variable;
- `GLP_BV` – binary variable; ...

`glp_get_col_stat(glp_prob *P, int j)` returns current status assigned to the structural variable associated with j-th column as follows:

- `GLP_BS` – basic variable;
- `GLP_NL` – non-basic variable on its lower bound;
- `GLP_NU` – non-basic variable on its upper bound; ...

`glp_get_col_prim(glp_prob *P, int j)` returns primal value of the structural variable associated with j-th column.

Sei x_i eine ganzzahlige Strukturvariable, die nach der LP-Relaxierung einen nicht-ganzzahligen Wert \hat{x}_i hat. Dann fügen wir entweder neue Schranken hinzu oder wir ändern bereits hinzugefügte Schranken in der folgenden Weise:

- Falls x_i nicht begrenzt war, fügen wir $x_i \leq \lfloor \hat{x}_i \rfloor$ bzw. $\lceil \hat{x}_i \rceil \leq x_i$ als neue Schranke hinzu.
- Falls es bereits eine obere Schranke $x_i \leq c_2$ gibt, dann ändern wir diese Schranke in $x_i \leq \lfloor \hat{x}_i \rfloor$ bzw. $\lceil \hat{x}_i \rceil \leq x_i \leq c_2$.
- Falls es eine untere Schranke $c_1 \leq x_i$ gibt, dann ändern wir diese Schranke in $c_1 \leq x_i \leq \lfloor \hat{x}_i \rfloor$ bzw. $\lceil \hat{x}_i \rceil \leq x_i$.
- Falls die Variable bereits nach beiden Seiten $c_1 \leq x_i \leq c_2$ beschränkt ist, ändern wir die Schranke in $c_1 \leq x_i \leq \lfloor \hat{x}_i \rfloor$ bzw. $\lceil \hat{x}_i \rceil \leq x_i \leq c_2$.

In allen obigen Fällen erhalten wir zwei neue Teilprobleme.

```
double getScore(glp_prob *p, int var) {
    // Most Fractional Branch
    double val = glp_get_col_prim(p, var);
    return 0.5 - fabs(val - floor(val) - 0.5);
}

pair<glp_prob *, glp_prob *> getBranches(glp_prob *job, int i){
    double val = glp_get_col_prim(job, i);
    double ub = floor(val);
    double lb = ub + 1.0;

    glp_prob *lp = glp_create_prob();
    glp_copy_prob(lp, job, GLP_OFF);
    glp_prob *rp = glp_create_prob();
    glp_copy_prob(rp, job, GLP_OFF);

    int type = glp_get_col_type(job, i);
    double lower = glp_get_col_lb(job, i);
    double upper = glp_get_col_ub(job, i);
```

```
int lType, rType;

if (type == GLP_DB) {
    lType = GLP_DB;
    rType = GLP_DB;
} else if (type == GLP_LO) {
    lType = GLP_DB;
    rType = GLP_LO;
} else if (type == GLP_UP) {
    lType = GLP_UP;
    rType = GLP_DB;
} else {
    lType = GLP_UP;
    rType = GLP_LO;
}
```

```
if (lower >= ub) {
    ub = lower;
    lType = GLP_FX;
}
glp_set_col_bnds(lp, i, lType, lower, ub);

if (lb >= upper) {
    lb = upper;
    rType = GLP_FX;
}
glp_set_col_bnds(rp, i, rType, lb, upper);

return pair<glp_prob *, glp_prob *>(lp, rp);
}
```

```
int main(int argc, char *argv[]) {
    if (argc != 2) {
        cout << "usage: " << argv[0]
            << " filename" << endl;
        return 1;
    }

    double opt;
    char *file = argv[1];

    glp_prob *lp = glp_create_prob();
    if (glp_read_mps(lp, GLP_MPS_FILE, 0, file)){
        cout << file << " not found" << endl;
        return 1;
    }

    // disable terminal output
    glp_term_out(GLP_OFF);
```

```
int objDir = glp_get_obj_dir(lp);

if (objDir == GLP_MAX)
    opt = -DBL_MAX;
else opt = DBL_MAX;

glp_adv_basis(lp, 0);
int rc = glp_simplex(lp, 0); // lp relaxation

if (rc != 0 || glp_get_status(lp) != GLP_OPT){
    cout << "error" << endl;
    return 1;
}
cout << "==> lp-relax: ";
if (objDir == GLP_MIN)
    cout << "lower bound ";
else cout << "upper bound ";
cout << glp_get_obj_val(lp) << " <==" << endl;
```

```
list<glp_prob *> pool;

pool.push_back(lp);
while ( ! pool.empty() ) {
    glp_prob *job = pool.front();
    pool.pop_front();

    glp_adv_basis(job, 0);
    rc = glp_simplex(job, 0);    // lp relaxation

    if (0 != rc || glp_get_status(job) != GLP_OPT) {
        // no valid solution found ==> continue with next job
        glp_delete_prob(job);
        continue;
}
```

```
double val = glp_get_obj_val(job);
if ((objDir == GLP_MAX && val <= opt)
    || (objDir == GLP_MIN && val >= opt)) {
    // current solution is bad ===> bound
    glp_delete_prob(job);
    continue;
}

int i = getBranchVariable(job);

if (i == -1) {
    if ((objDir == GLP_MAX && val > opt)
        || (objDir == GLP_MIN && val < opt)){
        opt = val;
        cout << "solution: " << val << endl;
    }
    glp_delete_prob(job);
    continue;
}
```

```
pair<glp_prob *, glp_prob *> probs = getBranches(job, i);

// Depth First Search
pool.push_front(probs.first);
pool.push_front(probs.second);

glp_delete_prob(job);
}

cout << ">>> value: " << opt << " <<<" << endl;

return 0;
}
```

Darstellen boolescher Logik mittels Integer Programmen

$y = \neg x$ wird zu $y = 1 - x$

x	$\neg x$	y	$y = \neg x$
0	1	0	0
0	1	1	1
1	0	0	1
1	0	1	0

\rightsquigarrow

x	$1 - x$	y	$y = 1 - x$
0	1	0	0
0	1	1	1
1	0	0	1
1	0	1	0

$x \Rightarrow y$ wird zu $x \leq y$

x	y	$x \Rightarrow y$
0	0	1
0	1	1
1	0	0
1	1	1

\rightsquigarrow

x	y	$x \leq y$
0	0	1
0	1	1
1	0	0
1	1	1

Darstellen boolescher Logik mittels Integer Programmen

$$z = x \vee y \text{ wird zu } 0 \leq 2 \cdot z - x - y \leq 1$$

x	y	z	$z = x \vee y$
0	0	0	1
0	0	1	0
0	1	0	0
0	1	1	1
1	0	0	0
1	0	1	1
1	1	0	0
1	1	1	1

\rightsquigarrow

x	y	z	$0 \leq 2 \cdot z - x - y \leq 1$
0	0	0	1
0	0	1	0
0	1	0	0
0	1	1	1
1	0	0	0
1	0	1	1
1	1	0	0
1	1	1	1

allgemein: $y = x_1 \vee x_2 \vee \dots \vee x_n$ wird zu $0 \leq n \cdot y - \sum_i x_i \leq n - 1$

Darstellen boolescher Logik mittels Integer Programmen

$z = x \wedge y$ wird zu $0 \leq x + y - 2 \cdot z \leq 1$

x	y	z	$z = x \wedge y$
0	0	0	1
0	0	1	0
0	1	0	1
0	1	1	0
1	0	0	1
1	0	1	0
1	1	0	0
1	1	1	1

\rightsquigarrow

x	y	z	$0 \leq x + y - 2 \cdot z \leq 1$
0	0	0	1
0	0	1	0
0	1	0	1
0	1	1	0
1	0	0	1
1	0	1	0
1	1	0	0
1	1	1	1

allgemein: $y = x_1 \wedge x_2 \wedge \dots \wedge x_n$ wird zu $0 \leq \sum_i x_i - n \cdot y \leq n - 1$

Darstellen boolescher Logik mittels Integer Programmen

Der Ausdruck

$$(x \wedge y) \Rightarrow z \equiv \neg(x \wedge y) \vee z \equiv \neg x \vee \neg y \vee z$$

wird zu $(1 - x) + (1 - y) + z \geq 1$

x	y	z	$(x \wedge y) \Rightarrow z$
0	0	0	1
0	0	1	1
0	1	0	1
0	1	1	1
1	0	0	1
1	0	1	1
1	1	0	0
1	1	1	1

~

x	y	z	$(1 - x) + (1 - y) + z \geq 1$
0	0	0	1
0	0	1	1
0	1	0	1
0	1	1	1
1	0	0	1
1	0	1	1
1	1	0	0
1	1	1	1

Darstellen boolescher Logik mittels Integer Programmen

$$\underbrace{\neg A \wedge \neg B \Rightarrow C = D}_{=:F} \sim \underbrace{C - D \leq A + B}_{=:X} \text{ und } \underbrace{-C + D \leq A + B}_{=:Y}$$

A	B	C	D	F	X	Y
0	0	0	0	1	1	1
0	0	0	1	0	1	0
0	0	1	0	0	0	1
0	0	1	1	1	1	1
0	1	0	0	1	1	1
0	1	0	1	1	1	1
0	1	1	0	1	1	1
0	1	1	1	1	1	1
1	0	0	0	1	1	1
1	0	0	1	1	1	1
\vdots				\vdots		

Use binary decision variables:

- $X_{i,t} = 1$ iff position i is empty after move t
- $Y_{i,j,t} = 1$ iff peg is moved from position i to j at time t

The objective is to maximize the number of empty holes in the final state:

$$\sum_i X_{i,T} \longrightarrow \max$$

T denotes the number of moves which depends on the number of pegs in the initial state and on the number of pegs in the final state, since after each move exactly one peg has been removed from the board.

We have to consider the following constraints:

- One jump per turn:

$$\sum_i \sum_{j \in D_i} Y_{i,j,t} = 1 \quad \forall t$$

- Jump to empty hole: $\bigvee_{j \in D_i} Y_{j,i,t} \Rightarrow X_{i,t}$

$$\sum_{j \in D_i} Y_{j,i,t} \leq X_{i,t} \quad \forall i, t$$

- Jump from occupied hole: $\bigvee_{j \in D_i} Y_{i,j,t} \Rightarrow \neg X_{i,t}$

$$\sum_{j \in D_i} Y_{i,j,t} \leq 1 - X_{i,t} \quad \forall i, t$$

D_i denotes the set of destination positions for a peg in position i .

further constraints:

- Jump over peg: $\bigvee_{(j,k) \in E_i} Y_{j,k,t} \Rightarrow \neg X_{i,t}$

$$\sum_{(j,k) \in E_i} Y_{j,k,t} \leq 1 - X_{i,t} \quad \forall i, t$$

- constraints to describe the initial and final state

E_i denotes the position pairs (j, k) such that a jump from position j over position i to position k is possible.

Further we have to ensure the balance equations:

$$X_{i,t} + \sum_{(j,k) \in E_i} Y_{j,k,t} + \sum_{j \in D_i} Y_{i,j,t} - \sum_{j \in D_i} Y_{j,i,t} = X_{i,t+1} \quad \forall i, t$$

The balance equation ensures:

- $X_{i,t} = X_{i,t+1}$ if position i is not involved in a move
- $X_{i,t} = 1$ and $X_{i,t+1} = 0$ if a move is made to i
- $X_{i,t} = 0$ and $X_{i,t+1} = 1$ if a move is made from i or over i

This IP model comes from:

G.W. DePuy and G.D. Taylor: Using board puzzles to teach operations research.
INFORMS Transactions on Education 7(2), 160 – 171 (2007)

Planen mittels Integer Programming: Knight Tour

1				
	2			

1				
		2		
	3			

1	24	13	18	7
14	19	8	23	12
9	2	xx	6	17
20	15	4	11	22
3	10	21	16	5

...

Use binary decision variables:

- $X_{i,t} = 1$ iff square i contains the knight at time t
- $Y_{i,j,t} = 1$ iff at time t the knight is moved from square i to j

The objective is to maximize the number of moves:

$$\sum_i \sum_{j \in D_i} \sum_t Y_{i,j,t} \longrightarrow \max$$

D_i denotes the set of feasible positions that can be reached by the knight from square i .

We have to consider the following constraints:

- the knight stands on one square per turn:

$$\sum_i X_{i,t} = 1 \quad \forall t$$

- the knight visits each square once over time:

$$\sum_t X_{i,t} = 1 \quad \forall i$$

- exactly one move is made per turn:

$$\sum_i \sum_{j \in D_i} Y_{i,j,t} = 1 \quad \forall t$$

- a move from square i requires the knight to be there:

$$\bigvee_{j \in D_i} Y_{i,j,t} \Rightarrow X_{i,t} \quad \leadsto \quad \sum_{j \in D_i} Y_{i,j,t} \leq X_{i,t} \quad \forall i, t$$

Further we have to ensure the balance equation:

$$X_{i,t} - \sum_{j \in D_i} Y_{i,j,t} + \sum_{j \in D_i} Y_{j,i,t} = X_{i,t+1} \quad \forall i, t$$

The balance equation ensures:

- $X_{i,t} = X_{i,t+1}$ if square i is not involved in a move
- $X_{i,t} = 1$ and $X_{i,t+1} = 0$ if a move is made from i
- $X_{i,t} = 0$ and $X_{i,t+1} = 1$ if a move is made to i

Knight-Tour problem is efficiently solvable, see

I. Parberry: An efficient algorithm for the knight's tour problem. Discrete Applied Mathematics 73(3), 251 – 260 (1997)

Planen mittels Integer Programming: 15-Puzzle

2	6	3
1	7	8
4	5	

2	6	3
1	7	8
4		5

2	6	3
1		8
4	7	5

2		3
1	6	8
4	7	5

	2	3
1	6	8
4	7	5

...

Use binary decision variables:

- $X_{i,k,t} = 1$ iff square i contains number k at time t
number 0 denotes the missing tile
- $Y_{i,j,t} = 1$ iff at time t the numbers of the squares i and j exchange places

The objective is to minimize the number of moves:

$$\sum_i \sum_{j \in D_i} \sum_t Y_{i,j,t} \longrightarrow \min$$

D_i denotes the set of destination positions if the empty tile is in square i . Value T denotes the number of moves which must be chosen large enough.

We have to consider the following constraints:

- exchange at most one pair of squares per turn:

$$\sum_i \sum_{j \in D_i} Y_{i,j,t} \leq 1 \quad \forall t$$

- each square contains exactly one number at each time:

$$\sum_k X_{i,k,t} = 1 \quad \forall i, t$$

- the puzzle contains each number exactly once per time:

$$\sum_i X_{i,k,t} = 1 \quad \forall k, t$$

- if empty tile is moved from square i to j
 - then square i holds 0 at time t :

$$Y_{i,j,t} \Rightarrow X_{i,0,t} \rightsquigarrow Y_{i,j,t} \leq X_{i,0,t} \quad \forall i, j \in D_i, t$$

- then square j holds 0 at time $t + 1$:

$$Y_{i,j,t} \Rightarrow X_{j,0,t+1} \rightsquigarrow Y_{i,j,t} \leq X_{j,0,t+1} \quad \forall i, j \in D_i, t$$

- and square j holds number k , then square i holds k afterwards:

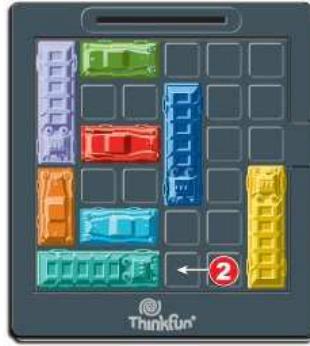
$$Y_{i,j,t} \wedge X_{j,k,t} \Rightarrow X_{i,k,t+1} \rightsquigarrow 1 - Y_{i,j,t} + 1 - X_{j,k,t} + X_{i,k,t+1} \geq 1 \quad \forall i, j \in D_i, t, k > 0$$

- if no exchange between squares i and j has been made, then $X_{i,k,t} = X_{i,k,t+1}$.

$$X_{i,k,t} - X_{i,k,t+1} \leq \sum_{j \in D_i} Y_{i,j,t} + \sum_{j \in D_i} Y_{j,i,t} \quad \forall i, k, t$$

$$-X_{i,k,t} + X_{i,k,t+1} \leq \sum_{j \in D_i} Y_{i,j,t} + \sum_{j \in D_i} Y_{j,i,t} \quad \forall i, k, t$$

Planen mittels Integer Programming: Rush-Hour



Use binary decision variables, where the marker denotes the upper left position of a vehicle:

- $X_{v,j,t} = 1$ iff marker of vehicle v is at position j at time t
- $Z_{v,j,t} = 1$ iff vehicle v occupies position j at time t .
- $Y_{v,i,j,t} = 1$ iff vehicle v moves marker from position i to position j at time t .

The objective is to minimize the number of moves:

$$\sum_v \sum_{i \in B_v} \sum_{j \in B_v} \sum_t Y_{v,i,j,t} \longrightarrow \min$$

B_v denotes the set of possible positions of marker of vehicle v .

The number of moves T must be chosen large enough to be able to solve the problem.

We have to consider the following constraints:

- at most one vehicle in a position:

$$\sum_v Z_{v,i,t} \leq 1 \quad \forall i, t$$

- move at most one vehicle per turn:

$$\sum_v \sum_{i \in B_v} \sum_{j \in B_v} Y_{v,i,j,t} \leq 1 \quad \forall t$$

- define positions occupied by vehicles:

$$L_v \cdot X_{v,i,t} \leq \sum_{m \in M_{v,i}} Z_{v,m,t} \quad \forall v, i, t$$

L_v denotes the length of vehicle v , and $M_{v,j}$ denotes the set of positions occupied by vehicle v if its marker is in position j .

Further constraints:

- take note of occupied positions:

$$Y_{v,i,j,t} \leq 1 - \sum_{w \neq v} Z_{w,p,t-1} \quad \forall v, i, j, t, p \in P_{v,i,j}$$

$P_{v,i,j}$ denotes the set of positions between i and j that vehicle v may reach.

- update marker for vehicles:

$$X_{v,i,t-1} - \sum_{j \in B_v} Y_{v,i,j,t} + \sum_{j \in B_v} Y_{v,j,i,t} = X_{v,i,t} \quad \forall v, i, t$$

Vorgehen bei gegebener Modellierung mittels STRIPS:

- Wird eine Aktion a durchgeführt, dann müssen vorher die PRE-Conditions und hinterher die ADD-Effects gelten, die DEL-Effects dürfen nicht mehr gelten:

$$\begin{aligned} a_t &\rightarrow p_t \quad \forall p \in \text{pre}(a) \\ a_t &\rightarrow p_{t+1} \quad \forall p \in \text{add}(a) \\ a_t &\rightarrow \neg p_{t+1} \quad \forall p \in \text{del}(a) \end{aligned}$$

- Parallele, widersprüchliche Aktionen werden ausgeschlossen:

$$a_t \rightarrow \neg b_t \quad \forall a, b : \text{del}(a) \cap (\text{pre}(b) \cup \text{add}(b)) \neq \emptyset$$

- Bei einem Wechsel des Zustands muss eine entsprechende Aktion durchgeführt worden sein:

$$\begin{aligned} (\neg p_t \wedge p_{t+1}) &\rightarrow \bigvee_{p \in \text{add}(a)} a_t \\ (p_t \wedge \neg p_{t+1}) &\rightarrow \bigvee_{p \in \text{del}(a)} a_t \end{aligned}$$

`unstack(X, Y):`

- PRE: `upon(X, Y)`, `clear(X)`, `empty()`
- ADD: `clear(Y)`, `hold(X)`
- DEL: `upon(X, Y)`, `clear(X)`, `empty()`

Constraints im linearen Programm:

$$\begin{aligned} \text{unstack}[x, y, t] &\leq \text{upon}[x, y, t] \\ \text{unstack}[x, y, t] &\leq \text{clear}[x, t] \\ \text{unstack}[x, y, t] &\leq \text{empty}[t] \\ \text{unstack}[x, y, t] &\leq \text{clear}[y, t + 1] \\ \text{unstack}[x, y, t] &\leq \text{hold}[x, t + 1] \\ \text{unstack}[x, y, t] &\leq 1 - \text{upon}[x, y, t + 1] \\ \text{unstack}[x, y, t] &\leq 1 - \text{clear}[x, t + 1] \\ \text{unstack}[x, y, t] &\leq 1 - \text{empty}[t + 1] \end{aligned}$$

`stack(X, Y):`

- PRE: `clear(Y)`, `hold(X)`
- ADD: `upon(X, Y)`, `clear(X)`, `empty()`
- DEL: `clear(Y)`, `hold(X)`

Constraints im linearen Programm:

$$\begin{aligned} \text{stack}[x, y, t] &\leq \text{clear}[y, t] \\ \text{stack}[x, y, t] &\leq \text{hold}[x, t] \\ \text{stack}[x, y, t] &\leq \text{upon}[x, y, t + 1] \\ \text{stack}[x, y, t] &\leq \text{clear}[x, t + 1] \\ \text{stack}[x, y, t] &\leq \text{empty}[t + 1] \\ \text{stack}[x, y, t] &\leq 1 - \text{clear}[y, t + 1] \\ \text{stack}[x, y, t] &\leq 1 - \text{hold}[x, t + 1] \end{aligned}$$

`pickup(X):`

- PRE: `onTable(X)`, `clear(X)`, `empty()`
- ADD: `hold(X)`
- DEL: `onTable(X)`, `clear(X)`, `empty()`

Constraints im linearen Programm:

$$\begin{aligned}pickup[x, t] &\leq onTable[x, t] \\pickup[x, t] &\leq clear[x, t] \\pickup[x, t] &\leq empty[t] \\pickup[x, t] &\leq hold[x, t + 1] \\pickup[x, t] &\leq 1 - onTable[x, t + 1] \\pickup[x, t] &\leq 1 - clear[x, t + 1] \\pickup[x, t] &\leq 1 - empty[t + 1]\end{aligned}$$

`putdown(X):`

- PRE: `hold(X)`
- ADD: `onTable(X)`, `clear(X)`, `empty()`
- DEL: `hold(X)`

Constraints im linearen Programm:

$$\begin{aligned}putdown[x, t] &\leq hold[x, t] \\putdown[x, t] &\leq onTable[x, t + 1] \\putdown[x, t] &\leq clear[x, t + 1] \\putdown[x, t] &\leq empty[t + 1] \\putdown[x, t] &\leq 1 - hold[x, t + 1]\end{aligned}$$

Planen mittels Integer Programming: Blocks-World

Falls sich `upon(x, y)` geändert hat:

$$\begin{aligned} 1 - \text{upon}[x, y, t] + \text{upon}[x, y, t + 1] &\leq 1 + \text{stack}[x, y, t] \\ \text{upon}[x, y, t] + 1 - \text{upon}[x, y, t + 1] &\leq 1 + \text{unstack}[x, y, t] \end{aligned}$$

Falls sich `clear(x)` geändert hat:

$$\begin{aligned} 1 - \text{clear}[x, t] + \text{clear}[x, t + 1] \\ \leq 1 + \sum_y \text{unstack}[y, x, t] + \sum_y \text{stack}[x, y, t] + \text{putdown}[x, t] \\ \text{clear}[x, t] + 1 - \text{clear}[x, t + 1] \\ \leq 1 + \sum_y \text{stack}[y, x, t] + \sum_y \text{unstack}[x, y, t] + \text{pickup}[x, t] \end{aligned}$$

Falls sich `onTable(x)` geändert hat:

$$\begin{aligned} 1 - \text{onTable}[x, t] + \text{onTable}[x, t + 1] &\leq 1 + \text{putdown}[x, t] \\ \text{onTable}[x, t] + 1 - \text{onTable}[x, t + 1] &\leq 1 + \text{pickup}[x, t] \end{aligned}$$

Falls sich `empty()` geändert hat:

$$1 - \text{empty}[t] + \text{empty}[t + 1] \leq 1 + \sum_x \text{putdown}[x, t] + \sum_x \sum_y \text{stack}[x, y, t]$$

$$\text{empty}[t] + 1 - \text{empty}[t + 1] \leq 1 + \sum_x \text{pickup}[x, t] + \sum_x \sum_y \text{unstack}[x, y, t]$$

Falls sich `hold(x)` geändert hat:

$$1 - \text{hold}[x, t] + \text{hold}[x, t + 1] \leq 1 + \text{pickup}[x, t] + \sum_y \text{unstack}[x, y, t]$$

$$\text{hold}[x, t] + 1 - \text{hold}[x, t + 1] \leq 1 + \text{putdown}[x, t] + \sum_y \text{stack}[x, y, t]$$

Es darf nur eine Operation zur Zeit t ausgeführt werden:

$$\begin{aligned} & \sum_x \sum_y (stack[x, y, t] + unstack[x, y, t]) \\ & + \sum_x (pickup[x, t] + putdown[x, t]) \leq 1 \end{aligned}$$

Minimiere die Anzahl der ausgeführten Aktionen:

$$\begin{aligned} & \sum_x \sum_y \sum_t (stack[x, y, t] + unstack[x, y, t]) \\ & + \sum_x \sum_t (pickup[x, t] + putdown[x, t]) \longrightarrow \min \end{aligned}$$

Übung 9. Implementieren Sie das Integer-Programm zur Lösung des Brett-Solitär-Problems mittels GLPK und vergleichen Sie dessen Laufzeit mit der Laufzeit eines Programms in C++ für das Problem.

Übung 10. Erweitern Sie das Integer-Programm zur Lösung des Blocks-World-Problems, so dass mehrere Greifarme gleichzeitig Aktionen durchführen können. Implementieren Sie beide Programme mittels GLPK und vergleichen Sie deren Laufzeiten sowie die berechneten Lösungen.

Wie ist das Integer-Programm zu ändern, wenn der Tisch nur eine begrenzte Anzahl von Blöcken aufnehmen kann?

1 Übersicht

2 Geschichte und Anwendungen

3 Wissensrepräsentation

4 Zustandsraumsuche

5 Aussagenlogik

6 Prädikatenlogik

7 Prolog

1 Übersicht

2 Geschichte und Anwendungen

3 Wissensrepräsentation

- Semantische Netze

- Regeln

- Unsicheres Wissen

- Unscharfes Wissen

4 Zustandsraumsuche

5 Aussagenlogik

6 Prädikatenlogik

7 Prolog

Domänenwissen: Wissen über

- Objekte und
- ihre Beziehungen.

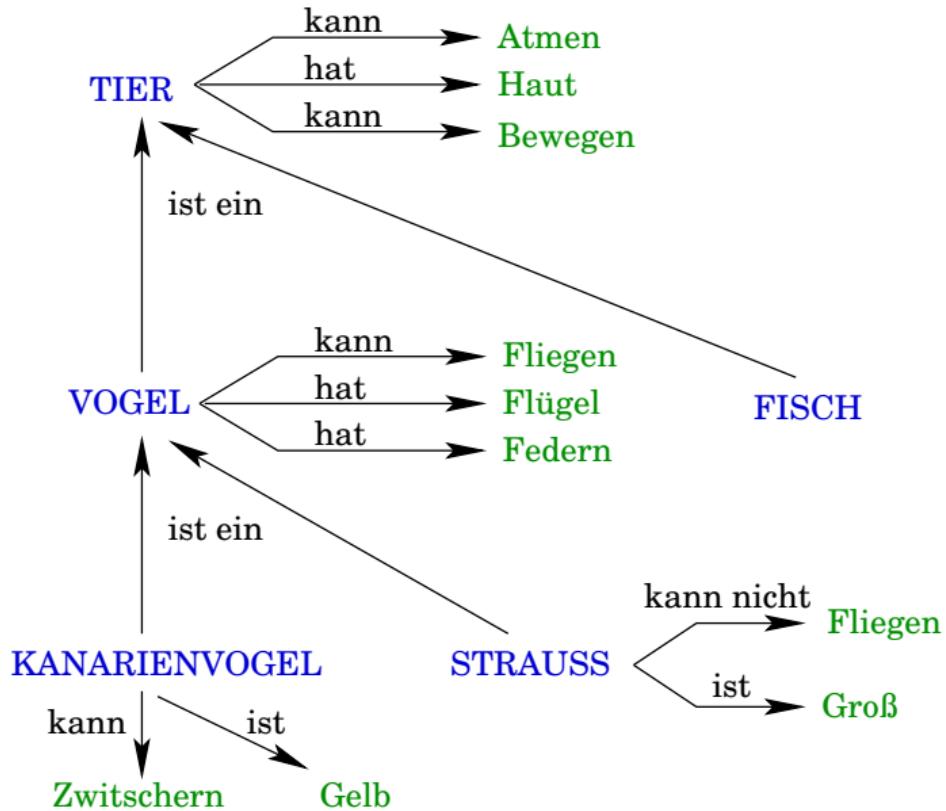
Semantische Netze:

- Stelle Wissen in einem Graphen dar:
 - Knoten entsprechen Fakten bzw. Konzepten und
 - Kanten entsprechen Relationen bzw. Assoziationen zwischen Konzepten.
- Sowohl Knoten als auch Kanten sind in der Regel mit Beschriftungen versehen.

Beziehungen zwischen Objekten können teilweise automatisch erkannt und für die Verarbeitung genutzt werden.

⁽⁴⁹⁾ aus George F. Luger: Künstliche Intelligenz

Semantische Netze



Semantische Netze entsprechen vielleicht der Speicherung von Informationen beim Menschen.
(Harmon und King, 1985)

Satz	Antwortzeit (s)
Ein Kanarienvogel ist ein Kanarienvogel.	1.0
Ein Kanarienvogel ist ein Vogel.	1.18
Ein Kanarienvogel ist ein Tier.	1.26
Ein Kanarienvogel kann zwitschern.	1.32
Ein Kanarienvogel kann fliegen.	1.38
Ein Kanarienvogel hat Haut.	1.48

Am schnellsten konnten die Informationen abgerufen werden, die spezifisch für den jeweiligen Vogel sind.

Auch auf spezifischer Ebene: Verarbeitung von Ausnahmen. Auf die Frage, ob Strauße fliegen können, wurde schneller geantwortet als auf die Frage, ob Strauße atmen können.

Relationen, also Kanten im Netz:

- Hierarchische Relationen:
 - Vererbung
 - Beispiel (Instanz)
 - Teile-Ganzes-Beziehung
- Synonymie (Bedeutungsgleichheit von Ausdrücken)
- Antonymie (Bedeutungsgegensatz von Ausdrücken)
- Kausation: ein Ereignis verursacht ein anderes
- Eigenschaft

Aktuelle Systeme:

- Shapiro: Semantic Network Processing System (SNePS)
- Helbig: MultiNet⁽⁵⁰⁾, mehrschichtiges erweitertes semantisches Netz zur Repräsentation natürlichsprachlichen Wissens.

⁽⁵⁰⁾<https://de.wikipedia.org/wiki/MultiNet>

Semantic Web: WWW als semantisches Netz

- bisher: WWW verknüpft Daten miteinander → Volltextsuche
- neu: Semantic Web verknüpft Informationen anhand ihrer Bedeutung miteinander
→ Ontologien

Beispiel:

- Page 1 enthält: Krefeld (Stadt) liegt am Rhein (Fluss).
- Page 2 enthält: Am Rhein (Fluss) ist es schön (Attribut).

⇒ In Krefeld (Stadt) ist es schön (Attribut).

- Dieser Schluss ist möglich, obwohl Informationen in verschiedenen Web-Pages liegen.

Um Krefeld als Ort von Krefeld als Nachname oder Unternehmen zu unterscheiden, müssen Daten mit zusätzlichen Informationen, also Metadaten, versehen werden.

Computer sind mit automatischer Beurteilung oft überfordert.

Beispiel: Manager und Handy als Suchbegriffe

- Ein Geschäftsführer *ist-ein* Manager. (Vererbung)
- Ein Vorstandsvorsitzender *ist-ein* Manager. (Vererbung)
- Walter Zabel *ist-ein* Geschäftsführer. (Instanz)
- Ein Handy *ist-ein* Mobiltelefon (Synonym)
- Ein Handy *ist-ein* mobiles Endgerät (Synonym)

→ Dokumente, in denen Walter Zabel und Mobiltelefon vorkommen, werden gefunden, auch wenn die Suchbegriffe Manager und Handy nicht im Text vorkommen.

Idee des Semantic Web:

- Inhalte des Hypertexts mit Metadaten beschreiben
- Ressourcenbeschreibung mittels Resource Description Framework (RDF)
- Modellierungssprache: Ontology Web Language (OWL)
- Ziel: Ausdrücke mit wohldefinierten und somit maschinell interpretierbaren Bedeutungen versehen

→ inhaltsbezogene Informationssuche

Suchtechnologien im Vergleich:

- Volltextsuche
 - Liefert alle Medieninhalte, die einen oder mehrere der Suchbegriffe beinhalten.
 - Erstellen des Index vollautomatisch → geringe Kosten
 - Darstellen der Ergebnisse in Listenform, schneller Zugriff auf ein Dokument.
- Thesaurus
 - Liefert alle Medieninhalte, die einen oder mehrere der Suchbegriffe oder verwandte, über- oder untergeordnete Begriffe beinhalten.
 - Beispiel: früher www.dr-antonius.de, heute <https://www.symptoma.de/>
- Semantische Netze
 - Orientiert sich im Gegensatz zu Thesaurus nicht nur an verwandten Begriffen, sondern an allen Assoziationen.
 - Zusammenhänge werden erfasst.

Anfrage:

- Kinderfreundliches Hotel mit Bademöglichkeit am Strand in Norddeutschland.

Linguistische Analyse:

- Hotel: Nomen
- kinderfreundlich: Adjektiv
- mit Bademöglichkeit am Strand: adverbiale Bestimmung
- in Norddeutschland: adverbiale Bestimmung

Synonymersetzung:

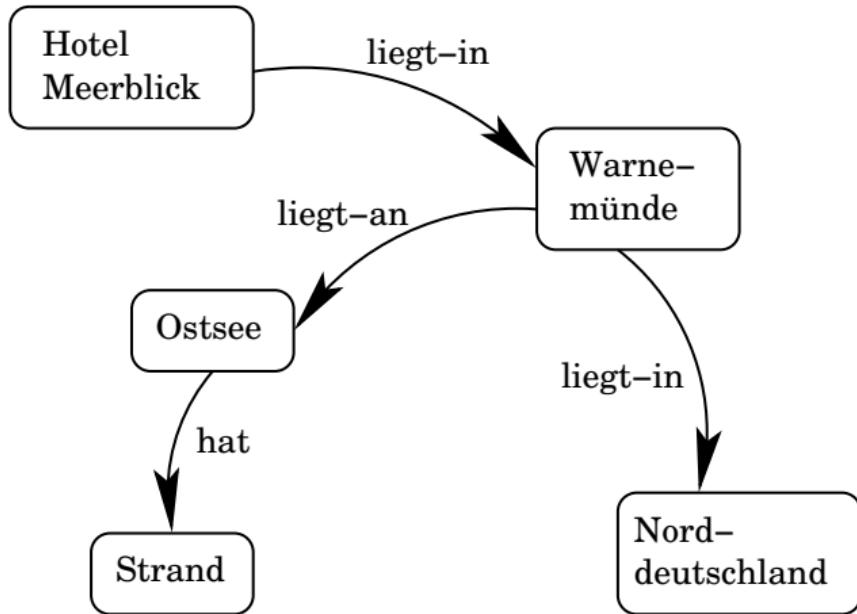
- familienfreundlich entspricht kinderfreundlich

Schlussfolgern:

- Norddeutschland ist-ein Teil von Deutschland
- Deutschland liegt-an Nordsee
- Deutschland liegt-an Ostsee
- Nordsee ist-ein Meer
- Ostsee ist-ein Meer
- Meer hat-ein Strand usw.

Abgleichen:

- Finde Hotels, die der Beschreibung nahe kommen.



→ Ontologie Web Language (OWL)

Ontologie-Schema:

- :Hotel rdf:type rdfs:Class.
→ Hotel ist vom Typ „Klasse“, also ein Konzept mit Instanzen
- :Lokation rdf:type rdfs:Class.
- :liegtIn rdf:type owl:TransitiveProperty
→ „liegtIn“ ist eine Relation (transitiv)
- usw.

Beispiele für Aussagen:

- :HotelMeerblick rdf:type :Hotel.
→ „Hotel Meerblick“ ist eine Instanz der Klasse „Hotel“
- :Warnemünde rdf:type :Lokation.
→ „Warnemünde“ ist eine Instanz von „Lokation“
- :Warnemünde :liegtIn :MecklenburgVorpommern.
- :MecklenburgVorpommern :liegtIn :Norddeutschland.
- :HotelMeerblick :liegtIn :Warnemünde.
- usw.

Abfragesprache SPARQL:

```
select ?hotel where {?hotel :liegtIn :Warnemünde}
```

Probleme:

- Benutzer sagen, dass komplexe SPARQL-Anfragen schwer zu formulieren sind.⁽⁵¹⁾
- Viele Web-Seiten⁽⁵²⁾ haben keine Meta-Daten (schema.org markup)

Lösung: LLM's (Large Language Models)

- können solche SPARQL-Anfragen generieren: LLM's are generating structured queries from user prompts and extracting structured knowledge from text.
- können diese Markup's automatisch erzeugen. Die Metadaten müssen also nicht mehr manuell erstellt werden.

Semantic Web: Past, Present, and Future. Ansgar Scherp, Gerd Groener, Petr Škoda, Katja Hose, Maria-Esther Vidal. <https://arxiv.org/abs/2412.17159>

⁽⁵¹⁾ Chatbot-Based Ontology Interaction Using Large Language Models and Domain-Specific Standards. J. Reif, T. Jeleniewski, M.S. Gill, F. Gehlhoff, A. Fay.

<https://arxiv.org/abs/2408.00800>

⁽⁵²⁾ The Web Data Commons Schema.org Data Set Series. A. Brinkmann, A. Primpeli, C. Bizer. https://www.uni-mannheim.de/media/Einrichtungen/dws/Files_Research/Web-based_Systems_Wissensbasierte_Systeme

1 Übersicht

2 Geschichte und Anwendungen

3 Wissensrepräsentation

- Semantische Netze

- Regeln

- Unsicheres Wissen

- Unscharfes Wissen

4 Zustandsraumsuche

5 Aussagenlogik

6 Prädikatenlogik

7 Prolog

Regeln sind formalisierte Konditionalsätze der Form „Wenn *A* dann *B*.“ mit der Bedeutung:

Wenn *A* wahr (erfüllt, bewiesen) ist,
dann schließe, dass auch *B* wahr ist.

Dabei wird *A* als *Prämissen* oder *Antezedenz* bezeichnet, *B* wird *Konklusion* oder *Konsequenz* genannt. Ist die Prämisse einer Regel erfüllt, so sagt man, dass die Regel *feuert*.

Regeln sind eine klassische, weit verbreitete Programmierform für Expertensysteme:

WENN (Batterie ok)
und (Wert Tankuhr > 0)
und (Benzinfilter sauber)
DANN (Problem = Zündanlage)

Regeln werden auch gerne in Produktionssystemen zur Steuerung eingesetzt, wobei die Konklusion oft mit einer Aktion verbunden ist:

- *Wenn* der Druck zu hoch ist, *dann* öffne das Ventil.
- *Wenn* die Motortemperatur zu hoch ist, *dann* prüfe die Kühlflüssigkeit.

Solche Regeln werden daher Produktionsregeln genannt.

Modellierung menschlichen Problemlöseverhaltens:

- Erfahrungen basieren auf Problemen, die der Experte früher gelöst hat.
- Diese Erfahrungen hat der Experte in Faustregeln abstrahiert. Wenn ein Experte mit einem neuen Problem konfrontiert wird, wendet er die passende Faustregel an.

Vorteile der Wissensdarstellung in Form von Regeln:

- Regeln stellen einen guten Kompromiss zwischen Verständlichkeit der Wissensdarstellung und formalen Ansprüchen dar.
- Konditionalsätze werden von Menschen seit langer Zeit benutzt, um Handlungsanweisungen oder Prognosen auszudrücken.
- Regeln sind dem Benutzer daher hinreichend vertraut.
- Ein großer Teil von Expertenwissen lässt sich üblicherweise in Regelform ausdrücken.
- Regeln haben eine große Nähe zum menschlichen Denken.

Es gibt verschiedene Arten von Regeln.

- *Produktionsregeln*: Falls in der aktuellen Datenbasis die Bedingung erfüllt ist, führe die Aktion aus.
- *Logische Regeln*: Falls in der aktuellen Datenbasis die Bedingung wahr ist, dann ist auch die Folgerung wahr.

Unterschied zwischen Regeln und IF-THEN-Anweisung in Programmiersprachen:

- Konventionelle Programme haben einen Kontrollfluss: Eine IF-THEN-Anweisung wird nur ausgeführt, wenn das Programm an die entsprechende Stelle kommt.
- In regelbasierten Systemen überprüft die Inferenzkomponente zu jedem Zeitpunkt alle Regeln, ob ihre Bedingung erfüllt ist. Regeln verhalten sich wie WHENEVER-THEN.

Beispiel für eine Regelbasis:

R1	WENN	(Anlasser arbeitet normal)
	DANN	(Batterie ok)
R2	WENN	(Batterie ok)
	und	(Wert Tankuhr > 0)
	und	(Benzinfilter sauber)
	DANN	(Problem = Zündanlage)
R3	WENN	(Batterie ok)
	und	(Wert Tankuhr > 0)
	und	(NICHT Benzinfilter sauber)
	DANN	(Defekt = Benzinleitung)
R4	WENN	(NICHT Scheibenwischer ok)
	und	(NICHT Licht ok)
	DANN	(Defekt = Batterie leer)

Fortsetzung:

R5 WENN (NICHT Wert Tankuhr > 0)
DANN (Defekt = Tank leer)

R6 WENN (Problem = Zündanlage)
und (Verteilerdose ok)
DANN (Defekt = Zündspule)

Fakten des aktuellen Falls:

F1 Anlasser arbeitet normal	F4 Wert Tankuhr > 0
F2 Scheibenwischer ok	F5 Benzinfilter sauber
F3 Licht ok	F6 Verteilerdose ok

Abgeleitete Fakten:

- A1 Batterie ok (R1 mit F1)
- A2 Problem = Zündanlage (R2 mit A1, F4 und F5)
- A3 Defekt = Zündspule (R6 mit A2 und F6)

Regelbasierte Systeme benötigen Suchverfahren

- zielorientierte Inferenz: Rückwärtsverkettung
- datengetriebene Inferenz: Vorwärtsverkettung

Um die Suche effizient zu gestalten sind Heuristiken wie die Mittel-Ziel-Analyse notwendig: Reduziere die Differenz zwischen dem aktuellen Zustand und dem Zielzustand (greedy). Wurde im General-Problem-Solver⁽⁵³⁾ (GPS) genutzt.

⁽⁵³⁾https://en.wikipedia.org/wiki/General_Problem_Solver

Wenn alle Bedingungen einer Regel durch Fakten der Wissensbasis erfüllt sind, dann führe die Aktion aus.

Recognize-Select-Act Zyklus:

- **Recognize:** Finde alle Regeln, deren Bedingungsteil erfüllt sind.
- **Select:** Wenn mehr als eine Regel anwendbar ist, wird eine Regel ausgewählt (Konfliktlösung).
- **Act:** Führe die Aktion der selektierten Regel aus.



Terminierungsbedingungen: Stop, wenn

- keine Regel mehr anwendbar ist oder
- wenn die Aktion „halt“ ausgeführt wird.

Oft sind wir nicht an allen ableitbaren Fakten interessiert. Daher geht man bei der **Rückwärtsverkettung** von einem Zielobjekt aus, über dessen Zustand der Benutzer Informationen wünscht.

- Das System durchsucht die Regelbasis nach geeigneten Regeln, die das Zielobjekt q in der Konklusion enthalten.
- Die Objekte der Prämisse werden zu Zwischenzielen. Bei einer Regel der Form $p_1 \wedge p_2 \wedge \dots \wedge p_n \rightarrow q$ werden also die Objekte p_1, p_2, \dots, p_n zu Zwischenzielen.
- Die Auswertung der Zwischenziele erfolgt rekursiv bis zu den Fakten. → Tiefensuche
- Die Regeln werden also vom Folgerungsteil zum Bedingungsteil hin ausgewertet.
- Dies entspricht der Vorgehensweise eines Prolog-Interpreters.

In der Praxis treten häufig Widersprüchlichkeiten in den Wissensbasen auf:

- Experten benutzen zur Ableitung ihrer Schlüsse oft unausgesprochene Annahmen
- oder übersehen, dass Regeln auch Ausnahmen haben können.

Beispiel:

if V then F	Regel	Alle Vögel können fliegen.
if $V \wedge P$ then $\neg F$	Ausnahme	Pinguine können nicht fliegen.

Wenn in diesem Beispiel sowohl V als auch P wahr sind, erhalten wir zwei Schlüsse: F und $\neg F$

Eine Konsistenzprüfung sollte den Benutzer bereits beim Aufbau einer Regelbasis auf solche Unstimmigkeiten hinweisen.

- Man legt i.d.R. Wert auf eine möglichst einfache syntaktische Form der Regeln.
- Dies ermöglicht eine effizientere Abarbeitung der Regeln und
- es verbessert die Übersichtlichkeit der Wirkung einzelner Regeln.

Üblicherweise stellt man folgende Bedingungen an die Form der Regeln (Prämissen \Rightarrow Konklusion):

- \vee (logisches Oder) darf nicht in der Prämissen einer Regel auftreten.
- Die Konklusion einer Regel sollte nur aus einem Literal bestehen.

Regeln, die diesen Bedingungen nicht genügen, müssen nach den Regeln der klassischen Logik umgeformt werden.

Wenn wir Regeln der Form

$$A \vee B \rightarrow C$$

$$A \rightarrow B \wedge C$$

$$A \rightarrow B \vee C$$

verbieten, dann müssen wir angeben, wie wir solche Regeln umformen:

$$\begin{aligned} A \vee B \rightarrow C &\iff \neg(A \vee B) \vee C && \text{Def. der Implikation} \\ &\iff (\neg A \wedge \neg B) \vee C && \text{de Morgan} \\ &\iff (\neg A \vee C) \wedge (\neg B \vee C) && \text{distributiv} \\ &\iff (A \rightarrow C) \wedge (B \rightarrow C) && \text{Def. der Implikation} \end{aligned}$$

Ebenso kann man herleiten:

$$\begin{aligned} A \rightarrow B \wedge C &\iff \neg A \vee (B \wedge C) && \text{Def. der Implikation} \\ &\iff (\neg A \vee B) \wedge (\neg A \vee C) && \text{distributiv} \\ &\iff (A \rightarrow B) \wedge (A \rightarrow C) && \text{Def. der Implikation} \end{aligned}$$

Nun müssen wir noch herleiten:

$$\begin{aligned} A \rightarrow B \vee C &\iff \neg A \vee (B \vee C) && \text{Def. der Implikation} \\ &\iff (\neg A \vee B) \vee C && \text{assoziativ} \\ &\iff \neg(A \wedge \neg B) \vee C && \text{de Morgan} \\ &\iff A \wedge \neg B \rightarrow C && \text{Def. der Implikation} \end{aligned}$$

Fassen wir oben bei der Anwendung des Assoziativgesetzes anders zusammen, nämlich $(\neg A \vee C) \vee B$, dann erhalten wir:

$$A \rightarrow B \vee C \iff A \wedge \neg C \rightarrow B$$

Fassen wir nun obige Umformungen zusammen und wenden sie auf ein Beispiel an.

Aus der Regel

$$A \vee B \rightarrow C \vee D$$

erhalten wir dann die vier Regeln:

$$A \wedge \neg C \rightarrow D \quad A \wedge \neg D \rightarrow C \quad B \wedge \neg C \rightarrow D \quad B \wedge \neg D \rightarrow C$$

Das ist auch intuitiv klar:

- Die linke Seite ist erfüllt, wenn A oder B wahr ist.
- In diesem Fall muss auch die rechte Seite wahr sein.
- Ist ein Teil der rechten Seite nicht wahr, dann muss der andere rechte Teil erfüllt sein.

Schauen wir uns das an einem konkreten Beispiel aus dem Alltag an.

Beispiel: Wenn es morgen regnet oder schneit, gehen wir ins Kino oder bleiben zu Hause.

Diese Regel lässt sich äquivalent durch die folgenden vier Regeln ausdrücken:

- Wenn es morgen regnet und wir nicht ins Kino gehen, dann bleiben wir zu Hause.
- Wenn es morgen regnet und wir nicht zu Hause bleiben, dann gehen wir ins Kino.
- Wenn es morgen schneit und wir nicht ins Kino gehen, dann bleiben wir zu Hause.
- Wenn es morgen schneit und wir nicht zu Hause bleiben, dann gehen wir ins Kino.

Nun erfüllt jede Regel die gestellten Anforderungen. Die Zahl der Regeln hat sich allerdings erhöht. Der Sinn dieser Umformungen wird im Kapitel Prädikatenlogik erklärt.

Deklarative Programmierung:

- Direkte Repräsentation von Expertenwissen.

Kein expliziter Kontrollfluss:

- Reihenfolge der Regeln spielt keine Rolle.
- Regeln sind aktiv sobald ihre Bedingung erfüllt ist.
- Konfliktlösung wählt eine der aktiven Regeln aus.

Problem:

- Wartung großer Regelsysteme ist aufwändig.
- Auswirkungen von Regeländerungen sind nicht direkt erkennbar.

Regeln sind nicht für alle Arten von Wissen geeignet.

1 Übersicht

2 Geschichte und Anwendungen

3 Wissensrepräsentation

- Semantische Netze
- Regeln
- **Unsicheres Wissen**

• Unscharfes Wissen

4 Zustandsraumsuche

5 Aussagenlogik

6 Prädikatenlogik

7 Prolog

Leider sind Fakten und Regeln nicht immer so eindeutig, wie wir sie bisher dargestellt haben:

- unsichere Fakten:
 - Der Temperatursensor hat eine Toleranz von $\pm 1^{\circ}\text{C}$.
 - Morgen wird es regnen.
- unscharfe Fakten:
 - Ab welcher Temperatur hat man hohes Fieber?
 - Ab wann ist der Druck im Kessel zu hoch?
- unvollständige Fakten: Fehlende Informationen werden durch Annahmen ersetzt.
- unsichere Regeln: „Wenn der Patient Fieber hat, dann hat er sehr wahrscheinlich eine bakterielle Infektion.“

Alle Schlussfolgerungen, die auf solchen Fakten oder Regeln basieren, sind unsicher.

Die klassische zweiwertige Logik mit den Wahrheitswerten 0 und 1 kann hier nicht angewendet werden.

Stattdessen drückt man durch Wahrscheinlichkeiten aus, mit welchem Maß man davon ausgehen kann, dass ein Ereignis eintritt.

Wahrscheinlichkeitsfunktion: Sei Ω ein endlicher Ereignisraum. Eine Funktion $p : 2^\Omega \rightarrow [0, 1]$ heißt Wahrscheinlichkeitsfunktion (oder Wahrscheinlichkeit), wenn gilt:

- $p(\Omega) = 1$
- $p(X \cup Y) = p(X) + p(Y)$ für $X, Y \subseteq \Omega$ und $X \cap Y = \emptyset$

⁽⁵⁴⁾aus U. Lämmel, J. Cleve: Lehr- und Übungsbuch Künstliche Intelligenz.

Für solche Wahrscheinlichkeitsfunktionen gilt mit $X, Y \subseteq \Omega$:

- *unmögliches Ereignis*: $p(\emptyset) = 0$
- *Monotonie*: $X \subseteq Y \Rightarrow p(X) \leq p(Y)$
- *Subtraktivität*: für $X \subseteq Y$ gilt: $p(Y - X) = p(Y \cap X^c) = p(Y) - p(X)$
denn $X \subseteq Y \Rightarrow Y = X \cup (Y \cap X^c)$, wobei X und $Y \cap X^c$ disjunkt sind, also gilt:
 $P(Y) = P(X) + P(Y \cap X^c) \iff P(Y \cap X^c) = P(Y) - P(X)$
- *Subadditivität*: $p(X \cup Y) \leq p(X) + p(Y)$
- *Additivität*: $p(X \cup Y) = p(X) + p(Y) - p(X \cap Y)$
- *Komplement*: $p(X^c) = 1 - p(X)$

Bedingte Wahrscheinlichkeit von X unter der Bedingung B :

$$p(X | B) = \frac{p(X \cap B)}{p(B)}$$

Beispiel: Welchen Wahrscheinlichkeitswert muss die Aussage „Wenn eine gerade Zahl gewürfelt wurde, dann ist es eine 2.“ bekommen?

- $X = \{2\}$: Es wurde eine 2 gewürfelt.
- $B = \{2, 4, 6\}$: Es wurde eine gerade Zahl gewürfelt.
- $p(X) = p(\{2\}) = \frac{1}{6}$
- $p(B) = p(\{2, 4, 6\}) = \frac{3}{6} = 0,5$
- $p(X | B) = p(\{2\} | \{2, 4, 6\}) = \frac{p(\{2\})}{p(\{2,4,6\})} = \frac{1}{3}$

Bayessche Formel:

$$p(X | B) = \frac{p(X \cap B)}{p(B)} = \frac{\frac{p(B \cap X)}{p(X)} \cdot p(X)}{p(B)} = \frac{p(B | X) \cdot p(X)}{p(B)}$$

Wenn die Berechnung von $p(X | B)$ verlangt ist, und $p(B | X)$ bekannt ist, dann kann die Schlussfolgerung „umgedreht“ werden.

Beispiel:

- X : Der Motor macht seltsame Geräusche. $p(X) = 0.08$
- Y : Der Motor braucht einen Ölwechsel. $p(Y) = 0.06$
- Ein dringend erforderlicher Ölwechsel sorgt in 60% der Fälle für seltsame Motorengeräusche. $p(X|Y) = 0.6$
- Mit welcher W.-keit deutet ein seltsames Motorgeräusch auf einen dringend erforderlichen Ölwechsel hin?

$$p(Y | X) = \frac{p(X | Y) \cdot p(Y)}{p(X)} = \frac{0.6 \cdot 0.06}{0.08} = 0.45$$

Anmerkung: In praktischen Anwendungen werden oft die Wahrscheinlichkeitstheoretischen Voraussetzungen nicht erfüllt.

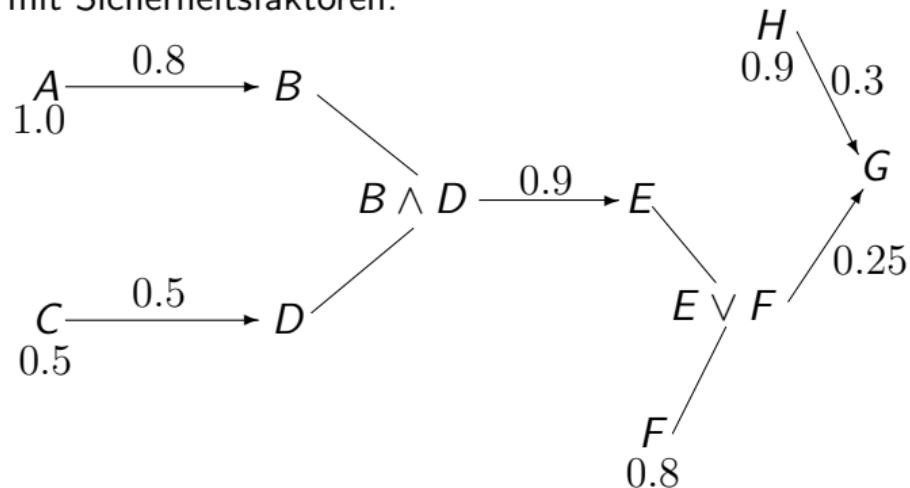
- Analytische Wahrscheinlichkeiten oder auf gesicherten statistischen Erhebungen basierende Wahrscheinlichkeiten sind problemlos.
- Rein subjektive Einschätzungen von Experten führen schnell zu Inkonsistenzen. Wären im obigen KFZ-Beispiel die Wahrscheinlichkeiten subjektiv ermittelt, und nimmt man $p(X) = 0.03$ an, dann ergäbe sich $p(Y|X) = 1.2$ als Wert der bedingten Wahrscheinlichkeit.

Bei subjektiven Einschätzungen ist der Begriff *Glaube* eher angebracht als der Begriff Wahrscheinlichkeit.

Bereits bei einem der ersten wissensbasierten Systeme überhaupt, dem medizinischen Diagnosesystem MYCIN, musste das Problem der Repräsentation und der Verarbeitung unsicheren Wissens gelöst werden.

- Regeln wurden mit einem Sicherheitsfaktor (certainty factor) versehen, einer reellen Zahl zwischen -1 und $+1$.
Sicherheitsfaktoren drücken den Grad des Glaubens an eine Hypothese aus.
 $CF(A \rightarrow B)$ gibt an, wie sicher die Konklusion B ist, wenn die Prämisse A wahr ist.
 - $CF(A \rightarrow B) = \pm 1$: B ist definitiv wahr/falsch
 - $CF(A \rightarrow B) = 0$: indifferente Haltung
- Auch die Sicherheit eines Fakts F wird mit einem solchen Sicherheitsfaktor $CF(F)$ quantifiziert.
- $CF(B | A)$ beschreibt den Modus Ponens: Aus $(A \rightarrow B \text{ und } A)$ folgt B , aber mit welcher Sicherheit gilt B ?

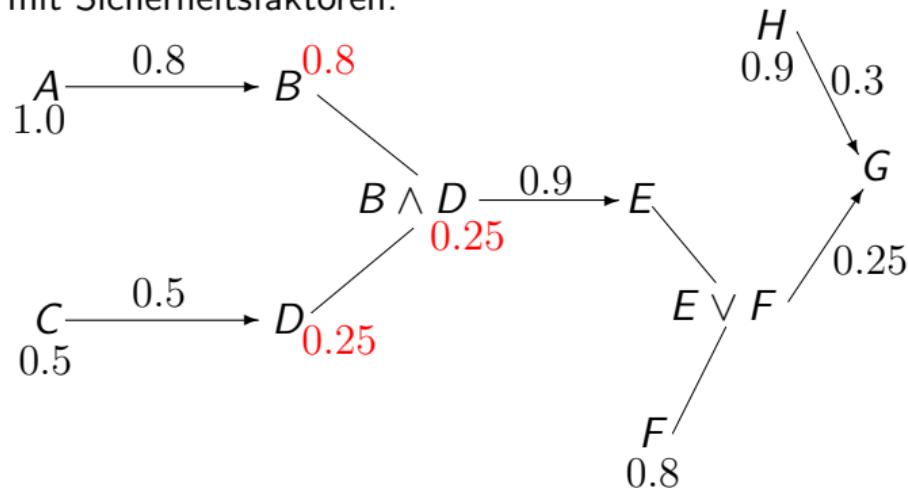
Inferenznetzwerk mit Sicherheitsfaktoren:



In MYCIN wurden folgende Propagationsregeln implementiert:

- Konjunktion: $CF(X \wedge Y) = \min\{CF(X), CF(Y)\}$
- Disjunktion: $CF(X \vee Y) = \max\{CF(X), CF(Y)\}$
- Kombination: $CF(Y | X) = CF(X \rightarrow Y) \cdot \max\{0, CF(X)\}$

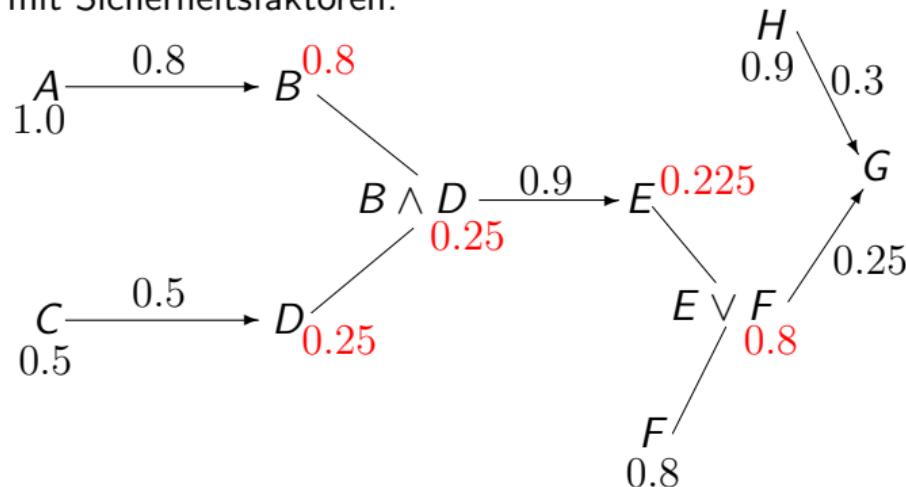
Inferenznetzwerk mit Sicherheitsfaktoren:



Beispiele:

- $CF(B | A) = CF(A \rightarrow B) \cdot CF(A) = 0.8 \cdot 1.0 = 0.8$
- $CF(D | C) = CF(C \rightarrow D) \cdot CF(C) = 0.5 \cdot 0.5 = 0.25$
- $CF(B \wedge D) = \min\{CF(B), CF(D)\} = 0.25$

Inferenznetzwerk mit Sicherheitsfaktoren:

Für G liegen zwei bestärkende Aussagen vor:

- $CF(G | H) = CF(H \rightarrow G) \cdot CH(H) = 0.3 \cdot 0.9 = 0.27$
- $CF(G | E \vee F) = CF(E \vee F \rightarrow G) \cdot CH(E \vee F) = 0.25 \cdot 0.8 = 0.2$
- ⇒ $CF(G | H, E \vee F)$ ist größer als $CF(G | H)$ und $CF(G | E \vee F)$.

parallele Kombination:

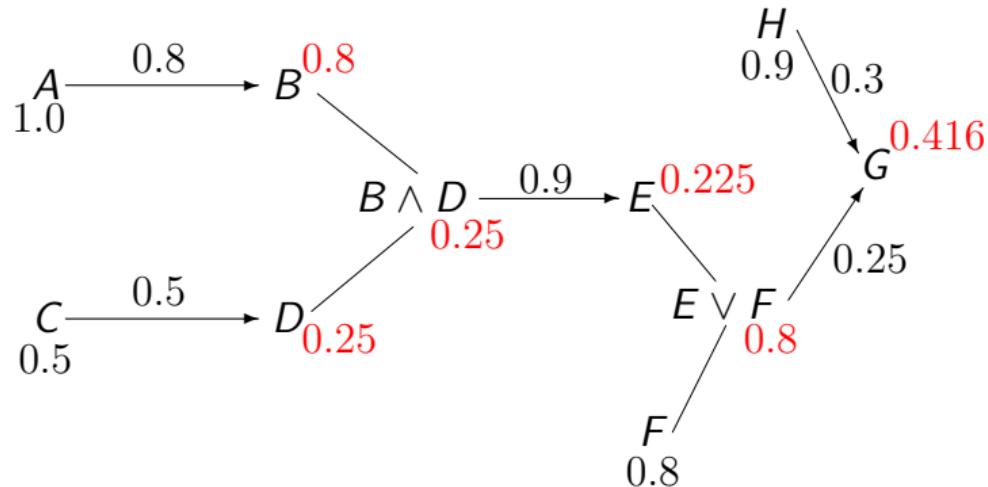
$$CF(B \mid A_1, A_2, \dots, A_n) = f(CF(B \mid A_1, A_2, \dots, A_{n-1}), CF(B \mid A_n))$$

Dabei ist $f : [0, 1] \times [0, 1] \rightarrow [0, 1]$ definiert als

$$f(x, y) := \begin{cases} x + y - xy & \text{wenn } x, y > 0 \\ x + y + xy & \text{wenn } x, y < 0 \\ \text{undefiniert} & \text{wenn } x \cdot y = -1 \\ \frac{x+y}{1-\min\{|x|,|y|\}} & \text{sonst} \end{cases}$$

In unserem Beispiel:

$$\begin{aligned} CF(G \mid H, E \vee F) &= f(CF(G \mid H), CF(G \mid E \vee F)) \\ &= CF(G \mid H) + CF(G \mid E \vee F) - CF(G \mid H) \cdot CF(G \mid E \vee F) \\ &= 0.27 + 0.2 - 0.054 = 0.416 \end{aligned}$$



Die Verwendung von Sicherheitsfaktoren ist nur eine heuristische Methode zur Repräsentation und Verarbeitung quantifizierter Unsicherheiten, die sich theoretisch nicht fundieren ließ. Dennoch erwies sie sich als recht leistungsstark und erfolgreich.

- Unscharfes Wissen

1 Übersicht

2 Geschichte und Anwendungen

3 Wissensrepräsentation

- Semantische Netze
- Regeln
- Unsicheres Wissen

4 Zustandsraumsuche

5 Aussagenlogik

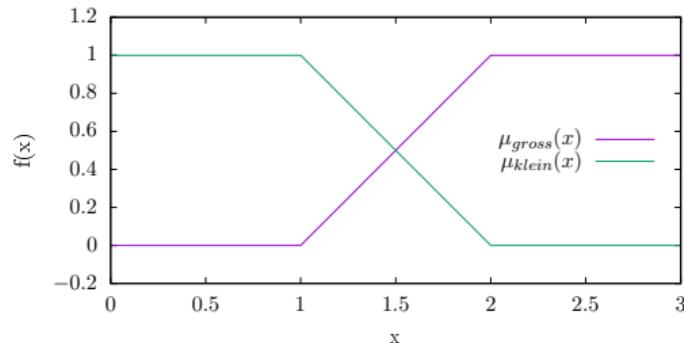
6 Prädikatenlogik

7 Prolog

Fuzzy-Mengen

Wie können unscharfe Aussagen wie groß/klein, jung/alt oder kalt/heiß modelliert werden?

Charakteristische Funktion: Beschreibt die Zugehörigkeit zu einer Klasse und lässt Werte zwischen 0 und 1 zu.



- Eine 2,10 m große Person, wird von allen als groß angesehen.
- Ein Säugling von 80 cm wird von allen als klein angesehen.

- Ein Volleyballspieler von 2,10 m wird eine 1,80 m große Person nicht als groß bezeichnen, für Kinder wird eine 1,80 m große Person sehr wohl groß sein.

Eine **Fuzzy-Menge** Z über einer Referenzmenge X ist eine Teilmenge aus $X \times [0, 1]$. Dabei wird Z durch die Zugehörigkeitsfunktion $\mu_Z : X \rightarrow [0, 1]$ beschrieben, wobei gilt:

$$z = (x, s) \in Z \iff \mu_Z(x) = s$$

Das Fuzzy-Konzept ist nur eine Verallgemeinerung der üblichen Mengenlehre, bei der wir auch Werte zwischen 0 und 1 erlauben. Klassisch:

$$\mu_A : X \rightarrow \{0, 1\} \quad \text{mit} \quad \mu_A(x) = \begin{cases} 1, & \text{falls } x \in A \\ 0, & \text{sonst} \end{cases}$$

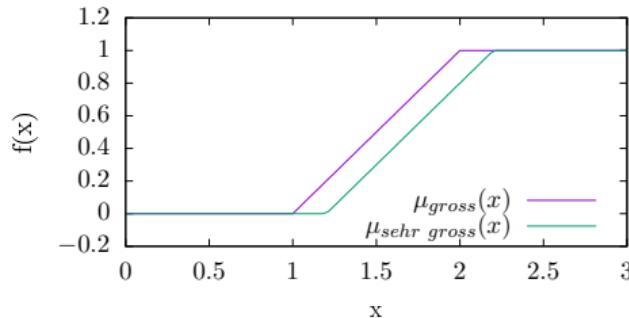
Um die Zugehörigkeit von x zur Fuzzy-Menge $M_{gross} \cap M_{klein}$ zur berechnen, müssen die Zugehörigkeitswerte von $\mu_{gross}(x)$ und $\mu_{klein}(x)$ geeignet verknüpft werden.

Fuzzy-Mengen

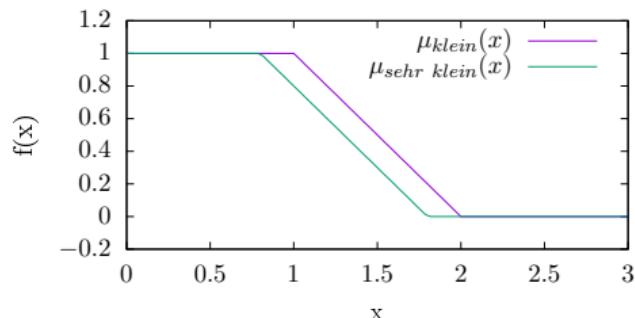
Teilmengenbeziehung: Seien Z_1 und Z_2 zwei Fuzzy-Mengen über X . Z_1 heißt Teilmenge von Z_2 , geschrieben $Z_1 \subset Z_2$, genau dann wenn für alle $x \in X$ gilt:

$$\mu_{Z_1}(x) \leq \mu_{Z_2}(x)$$

Beispiel: Die Menge $M_{\text{sehr gross}}$ der sehr großen Menschen ist eine Teilmenge der Menge M_{gross} der großen Menschen.



$$M_{\text{sehr gross}} \subseteq M_{\text{gross}}$$



$$M_{\text{sehr klein}} \subseteq M_{\text{klein}}$$

Durchschnitt zweier Fuzzy-Mengen:

Sei $S : [0, 1] \times [0, 1] \rightarrow [0, 1]$ eine Funktion mit den Eigenschaften:

- **neutrales Element:** $S(a, 1) = a$ für $a \in [0, 1]$.

Der Zugehörigkeitswert 1 steht dafür, dass das Element mit Sicherheit zur Fuzzy-Menge Z_2 gehört. Dann ist es plausibel, dass der Zugehörigkeitswert des Durchschnitts dem Zugehörigkeitswert zur Menge Z_1 entspricht.

- **Monotonie:** $a \leq b \Rightarrow S(a, c) \leq S(b, c)$ für $a, b, c \in [0, 1]$.
- **Kommutativität:** $S(a, b) = S(b, a)$ für $a, b \in [0, 1]$.
- **Assoziativität:** $S(a, S(b, c)) = S(S(a, b), c)$ für $a, b, c \in [0, 1]$.

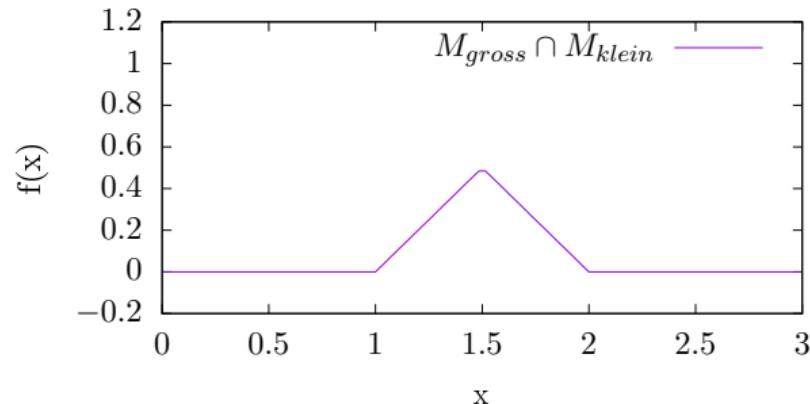
Eine solche Funktion S nennt man *t-Norm*.

Der Durchschnitt zweier Fuzzy-Mengen Z_1 und Z_2 wird definiert durch die Zugehörigkeitsfunktion $\mu_{Z_1 \cap Z_2} = S(\mu_{Z_1}(x), \mu_{Z_2}(x))$.

Mögliche Funktionen:

- $S(a, b) = \min(a, b)$
- $S(a, b) = a \cdot b$

Wählt man das Minimum, erhält man für den Schnitt von M_{gross} und M_{klein} :



Vereinigung zweier Fuzzy-Mengen:

Sei $V : [0, 1] \times [0, 1] \rightarrow [0, 1]$ eine Funktion mit den Eigenschaften:

- **neutrales Element:** $V(a, 0) = a$ für $a \in [0, 1]$.

Der Zugehörigkeitswert 0 steht dafür, dass das Element mit Sicherheit nicht zur Fuzzy-Menge Z_2 gehört. Dann ist es plausibel, dass der Zugehörigkeitswert der Vereinigung dem Zugehörigkeitswert zur Menge Z_1 entspricht.

- **Monotonie:** $a \leq b \Rightarrow V(a, c) \leq V(b, c)$ für $a, b, c \in [0, 1]$.
- **Kommutativität:** $V(a, b) = V(b, a)$ für $a, b \in [0, 1]$.
- **Assoziativität:** $V(a, V(b, c)) = V(V(a, b), c)$ für $a, b, c \in [0, 1]$.

Eine solche Funktion V nennt man *t-CoNorm*.

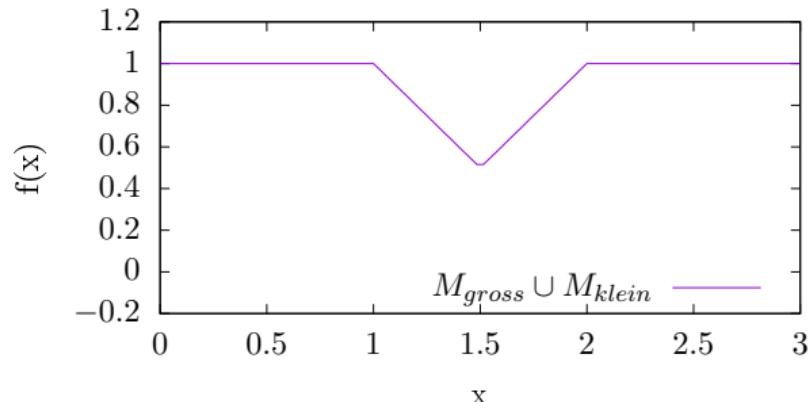
Fuzzy-Mengen

Die Vereinigung zweier Fuzzy-Mengen Z_1 und Z_2 wird definiert durch die Zugehörigkeitsfunktion $\mu_{Z_1 \cup Z_2} = V(\mu_{Z_1}(x), \mu_{Z_2}(x))$.

Mögliche Funktionen:

- $V(a, b) = \max(a, b)$
- $V(a, b) = a + b - a \cdot b$

Wählt man das Maximum, erhält man für die Vereinigung von M_{gross} und M_{klein} :



Die gewählte t-Norm und die t-CoNorm müssen zueinander passen, um die in der klassischen Logik geltenden Aussagen auch bei der Fuzzy-Logik zu erfüllen.

Beispiel: Minimum als t-Norm, Maximum als t-CoNorm. Dann gilt

$$A \vee (A \wedge B) = A$$

auch in der Fuzzy-Logik, denn es gilt:

$$\mu_{A \vee (A \wedge B)}(x) = \max \{ \mu_A(x), \min\{\mu_A(x), \mu_B(x)\} \} = \mu_A(x)$$

Die logische Negation $\neg A$ wird in der Fuzzy-Logik als $1 - \mu_A(x)$ realisiert.

Fuzzy-Logik

Wie wir aus der Aussagenlogik wissen, sind die Operatoren \vee , \wedge und \neg eine Basis. Daher können wir die Implikation $A \rightarrow B$ auch darstellen als $\neg A \vee B$. Die so definierte Zugehörigkeitsfunktion

$$\mu_{A \rightarrow B}(x) := \max\{1 - \mu_A(x), \mu_B(x)\}$$

geht auf Kleene und Dienes zurück. Es gibt weitere Definitionen für die Implikation:

Name	$\mu_{A \rightarrow B}(x)$
Lukasiewicz	$\min\{1, 1 - \mu_A(x) + \mu_B(x)\}$
Kleene-Dienes	$\max\{1 - \mu_A(x), \mu_B(x)\}$
Zadeh	$\max\{1 - \mu_A(x), \min\{\mu_A(x), \mu_B(x)\}\}$
Reichenbach	$1 - \mu_A(x) + \mu_A(x) \cdot \mu_B(x)$

Lotfi A. Zadeh gilt als Erfinder der Fuzzy-Logik (1965), University of California, Berkeley.

Machen wir uns zunächst klar, dass die Implikation $A \rightarrow B$ in der klassischen Aussagenlogik auf zwei verschiedene Arten vorkommt:

- Sind die Wahrheitswerte von A und B bekannt, dann kann auf den Wahrheitswert von $A \rightarrow B$ geschlossen werden.
- Modus Ponens: Wenn bekannt ist, dass die Regel $A \rightarrow B$ gilt, und wir den Wahrheitswert von A kennen, dann können wir auf den Wahrheitswert von B schließen.

In der Fuzzy-Logik ist es genauso: Sind die Zugehörigkeitswerte $\mu_A(x)$ und $\mu_B(x)$ von x bekannt, dann können wir nach einer der obigen Formeln den Zugehörigkeitswert $\mu_{A \rightarrow B}(x)$ von x berechnen.

Beim Schließen mittels Modus Ponens setzen wir die Gültigkeit der Regel voraus, und ermitteln aus dem Zugehörigkeitswert $\mu_A(x)$ den Zugehörigkeitswert $\mu_B(x)$.

Fuzzy-Control

Beispiel: Es gelte die Regel „große Menschen sind schwer“, und außerdem gelte „Hans ist groß“. Klassisch:

große Menschen sind schwer	vorhandenes	$A \rightarrow B$
Hans ist groß	Wissen	A
<hr/>	Schlussfolgerung	<hr/> B

In der Fuzzy-Logik sind unscharfe Werte gegeben. Wenn Hans 1,80 Meter groß ist, dann lesen wir den Zugehörigkeitswert $\mu_{gross}(1,8) = 0,8$ aus unserer Grafik ab: Hans ist *ziemlich* groß.

große Menschen sind schwer	vorhandenes
Hans ist <i>ziemlich</i> groß	Wissen
<hr/>	Schlussfolgerung

Wir übertragen die Werte der Fakten auf die Werte der Folgerung.

Werte einer *Linguistischen Variablen* sind Worte einer natürlichen Sprache. Bei der Temperatur unterscheiden wir oft die linguistischen Werte *kalt*, *kühl*, *normal*, *warm* und *heiß*.

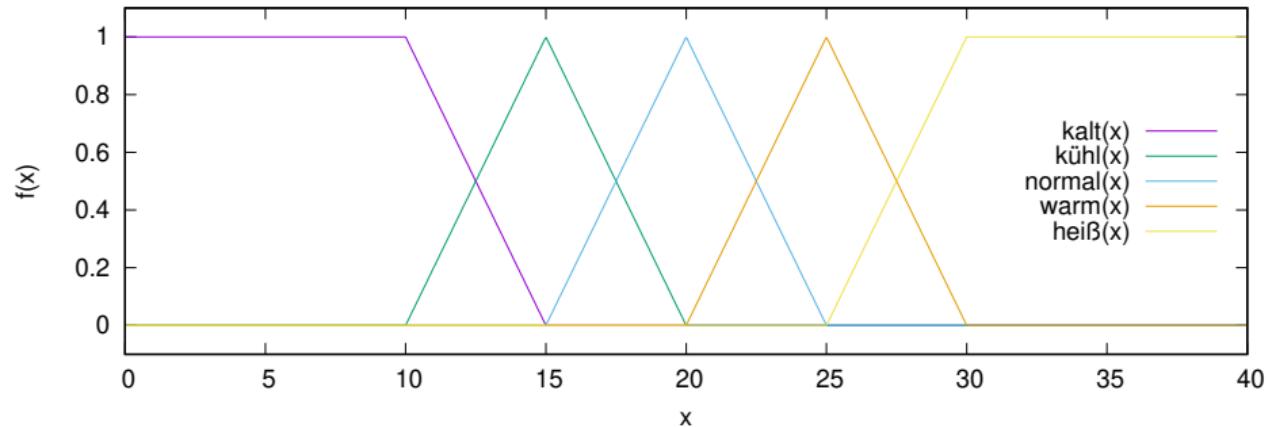
Diese Werte werden durch unscharfe Mengen A_i bzw. deren Zugehörigkeitsfunktionen $\mu_{A_i}(x)$ repräsentiert.

Die Zugehörigkeitsfunktionen bilden eine linguistische auf eine numerische Werteskala ab.

In der Praxis hat es sich als zweckmäßig erwiesen, die Zugehörigkeitsfunktionen durch stückweisen linearen Verlauf zu definieren. Es sind auch andere Verläufe möglich, wichtig ist nur, dass das Problem adäquat modelliert wird.

Fuzzy-Control

Wir weisen den Werten der linguistischen Variablen *kalt*, *kühl*, *normal*, *warm* und *heiß* Fuzzy-Mengen zu:



Wollen wir nun eine Heizungssteuerung implementieren, benötigen wir einige Regeln der Form:

- (1) *Wenn* $T_{innen} = \text{kühl}$ *Und* $T_{aussen} = \text{kalt}$ *Dann* Heizung = stark
- (2) *Wenn* $T_{innen} = \text{kühl}$ *Und* $T_{aussen} = \text{kühl}$ *Dann* Heizung = normal
- (3) *Wenn* $T_{innen} = \text{normal}$ *Und* $T_{aussen} = \text{kalt}$ *Dann* Heizung = normal
- (4) *Wenn* $T_{innen} = \text{normal}$ *Und* $T_{aussen} = \text{kühl}$ *Dann* Heizung = schwach

Ebenso wie für die Temperatur legen wir linguistische Werte *aus*, *schwach*, *normal*, *stark* und *voll* für die Leistung der Heizung fest.

Zu einer vollständigen Regelung benötigen wir noch weitere Regeln, aber die angegebenen reichen für unser Beispiel.

Fuzzy-Control

Wir gehen davon aus, dass wir innen und außen folgende Temperaturen gemessen haben.

$$T_{\text{innen}} = 17 \quad \text{und} \quad T_{\text{außen}} = 11$$

Diese Werte sehen wir als scharfe Werte an, so wie die Größe von Hans im vorigen Beispiel.

Wir bestimmen nun die Zugehörigkeitswerte zu den einzelnen Fuzzy-Mengen:

T	$\mu_{\text{kalt}}(T)$	$\mu_{\text{kühl}}(T)$	$\mu_{\text{normal}}(T)$	$\mu_{\text{warm}}(T)$	$\mu_{\text{heiß}}(T)$
innen = 17	0	0,6	0,4	0	0
außen = 11	0,8	0,2	0	0	0

Da wir Regeln der Form $A \wedge B \rightarrow C$ haben, müssen wir zunächst den Zugehörigkeitswert der linken Seite bestimmen. Dazu nutzen wir die Formel $\mu_{A \wedge B}(x) = \min\{\mu_A(x), \mu_B(x)\}$.

Wir haben bereits gesehen, dass wir den Zugehörigkeitsgrad der Prämisse für die Schlussfolgerung übernehmen. Welche Werte der linguistischen Variablen *Heizung* in der Tabelle stehen, wird durch die Regeln festgelegt:

T_{innen}	\wedge	T_{aussen}	\Rightarrow	Heizung	Regel
kühl = 0,6	\wedge	kalt = 0,8	\Rightarrow	stark = 0,6	(1)
kühl = 0,6	\wedge	kühl = 0,2	\Rightarrow	normal = 0,2	(2)
normal = 0,4	\wedge	kalt = 0,8	\Rightarrow	normal = 0,4	(3)
normal = 0,4	\wedge	kühl = 0,2	\Rightarrow	schwach = 0,2	(4)

Probleme:

- Zwei Regeln führen zur gleichen Aussage mit verschiedenen Zugehörigkeitsgraden.
- Die Heizung soll gleichzeitig stark, normal und schwach heizen.

Wir benötigen eine Verknüpfungsstrategie für die unscharfen Mengen, denen die Regeln in der Konklusion unterschiedliche Zugehörigkeitsgrade zuweisen. Es wurden verschiedene Strategien untersucht:

- Wähle das Maximum der Zugehörigkeitsgrade.
- Wähle den arithmetischen Mittelwert.
- Bilde die Summe der unscharfen Mengen: $\mu_{A+B} = \mu_A + \mu_B - \mu_A \cdot \mu_B$

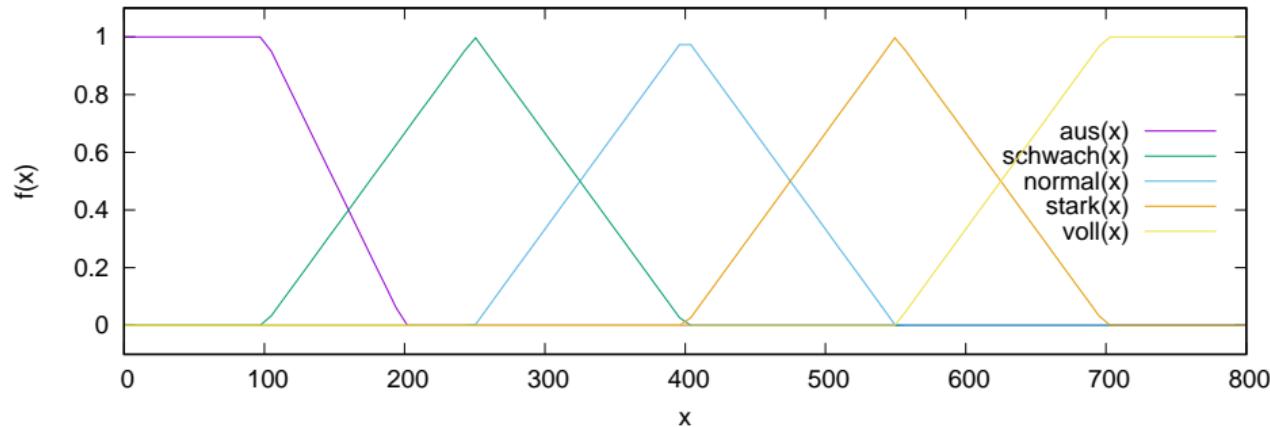
Welche Verknüpfungsstrategie gewählt wird hängt davon ab, welche die Prozesscharakteristik am besten beschreibt.

Wir wählen das Maximum der Werte und erhalten so:

$$\mu_{\text{stark}} = 0,6 \quad \mu_{\text{normal}} = 0,4 \quad \mu_{\text{schwach}} = 0,2$$

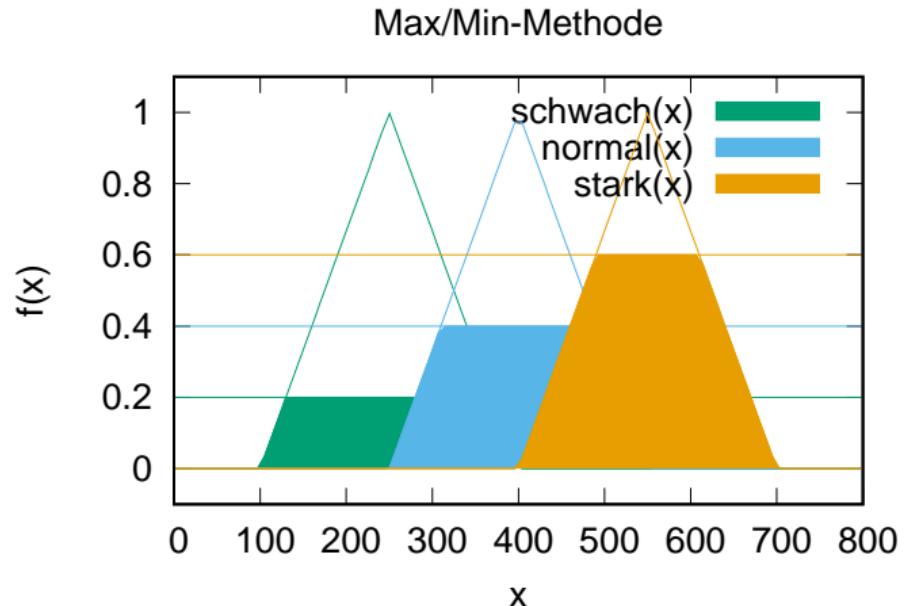
Fuzzy-Control

Wenn wir nun die Heizung regeln wollen, müssen wir die Zugehörigkeitswerte de-fuzzyfizieren:



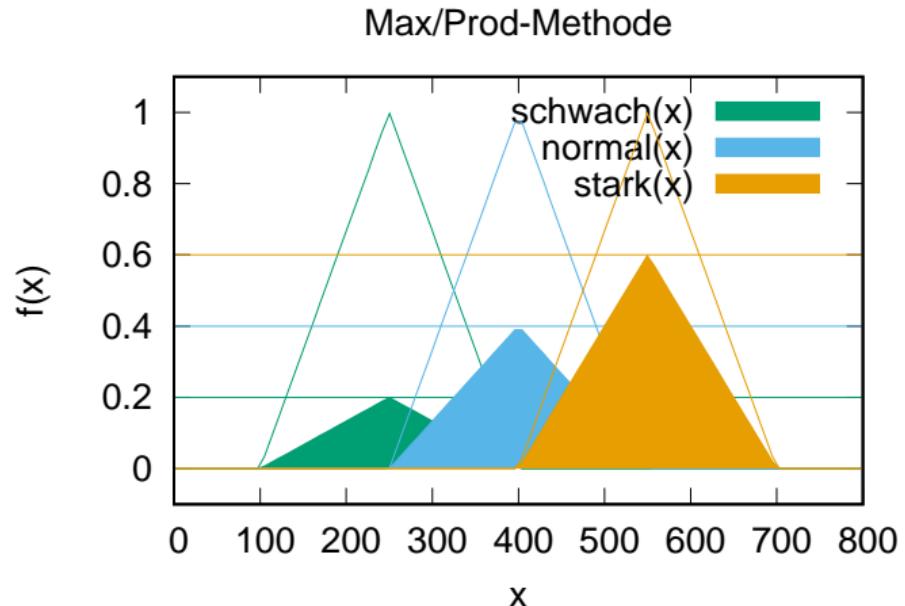
Für das De-Fuzzifizieren wurden ebenfalls mehrere Möglichkeiten untersucht. Betrachten wir zunächst die Max/Min-Methode.

Bei der Max/Min-Methode werden die Zugehörigkeitsfunktionen der einzelnen unscharfen Mengen in Höhe des jeweils ermittelten Zugehörigkeitsgrades abgeschnitten.



Fuzzy-Control

Bei der Max/Prod-Methode werden die Werte mit dem Zugehörigkeitsgrad multipliziert. Das bewirkt eine Stauchung der Zugehörigkeitsfunktionen.



Schließlich muss aus diesen Flächen ein einziger Wert ermittelt werden, der dann zur Steuerung genutzt werden kann. Oft wird dafür der Flächenschwerpunkt ermittelt:

$$x_s = \frac{\int_{x_A}^{x_E} x \cdot f(x) dx}{\int_{x_A}^{x_E} f(x) dx}$$

Dabei bedeutet:

- x_s ist die x -Koordinate des Flächenschwerpunktes
- x_A ist die x -Koordinate des Anfangswertes der Fläche
- x_E ist die x -Koordinate des Endwertes der Fläche
- $f(x)$ ist die Funktion, die die Berandung des Flächenstücks beschreibt

Der so ermittelte Wert x_s wird als Steuergröße für den Regelprozess verwendet.

1 Übersicht

2 Geschichte und Anwendungen

3 Wissensrepräsentation

4 Zustandsraumsuche

5 Aussagenlogik

6 Prädikatenlogik

7 Prolog

Für viele Probleme in der Informatik sind keine effizienten Algorithmen bekannt. Eine algorithmische Lösung eines solchen Problems besteht darin, alle potenziellen Lösungen durchzuprobieren, bis die richtige gefunden ist. Dies nennt man Brute-Force-Search⁽⁵⁵⁾ (rohe Gewalt) oder erschöpfende bzw. vollständige Suche (englisch exhaustive search).

Die Brute-Force-Suche ist einfach zu implementieren und dazu bestimmt, die korrekte Lösung zu finden. Allerdings steigt der Aufwand an Rechenoperationen proportional zur Anzahl der zu probierenden möglichen Lösungen, wobei die Anzahl dieser möglichen Lösungen mit zunehmendem Umfang der Probleme häufig exponentiell rasch wächst.

Hinweis: In der Mathematik bezeichnet eine Kombination eine ungeordnete Auswahl von Elementen einer Menge, die Reihenfolge der Elemente spielt also keine Rolle, wohingegen eine Variation eine geordnete Auswahl bezeichnet, die Reihenfolge der Elemente also wichtig ist. $\{a, b, c\} = \{b, c, a\}$ vs. $(a, b, c) \neq (b, c, a)$

Im normalen Sprachgebrauch ist das oft nicht so. Bei der Kombination eines Zahlenschlosses bspw. ist die Reihenfolge der Ziffern wichtig.

⁽⁵⁵⁾<https://de.wikipedia.org/wiki/Brute-Force-Methode>

Übung 11.

Betrachten Sie die folgenden Probleme.

- *traveling salesman*: Für jede Permutation P der Knoten V berechne die Länge der repräsentierten Tour. Basiert auf dem systematischen Aufzählen aller Permutationen⁽⁵⁶⁾.
- *clique*: Für jede k -elementige Teilmenge V' der Knoten V teste, ob V' eine Clique ist. Basiert auf dem Aufzählen k -elementiger Teilmengen.
- *maximum clique*: Für jede Teilmenge V' von V teste, ob V' eine Clique ist. Basiert auf dem systematischen Aufzählen aller Teilmengen einer Menge⁽⁵⁷⁾.
- *mastermind*: Für jede Variation (mit Wiederholung) F der Farben, nutze die Rückmeldung, um den nächsten Zug zu optimieren, siehe Seite 40. Basiert auf dem systematischen Aufzählen aller Variationen.

Wie kann man systematisch die obigen Mengen oder Listen aufzählen?

⁽⁵⁶⁾besser: Held-Karp-Algorithmus

⁽⁵⁷⁾besser: Bron-Kerbosch-Algorithmus

Obige Methoden sind viel zu langsam.

- Sehr viele Probleme der Wissensverarbeitung lassen sich auf ein Suchproblem zurückführen.
- Die Eigenschaften und Lösungsverfahren von Suchproblemen sind daher von grundlegender Bedeutung für die Wissensverarbeitung.
- Suchverfahren sind ein klassisches Kapitel innerhalb der Wissensverarbeitung.
- Wir werden die Zustandsraumsuche im wesentlichen bei Spielen kennen lernen.

Färbeproblem



Beispiel: Die angegebene Landkarte ist so mit den Farben rot, blau, gelb und grün zu färben, dass keine zwei benachbarten Länder die gleiche Farbe haben.

- Ein naives generate-and-test Verfahren würde 4^7 mögliche Farbkonstellationen prüfen.
- Allgemein sind m^n Farbkonstellationen zu prüfen, mit $m :=$ Anzahl der Farben und $n :=$ Anzahl der Länder.
⇒ Ineffizient!

Färbeproblem

Naives generate-and-test Verfahren:

WA	NT	SA	QL	NSW	Vic	Tas
rot	rot	rot	rot	rot	rot	rot
rot	rot	rot	rot	rot	rot	blau
rot	rot	rot	rot	rot	rot	grün
rot	rot	rot	rot	rot	rot	gelb
rot	rot	rot	rot	rot	blau	rot
rot	rot	rot	rot	rot	blau	blau
rot	rot	rot	rot	rot	blau	grün
rot	rot	rot	rot	rot	blau	gelb
rot	rot	rot	rot	rot	grün	rot
rot	rot	rot	rot	rot	grün	blau
rot	rot	rot	rot	rot	grün	grün
rot	rot	rot	rot	rot	grün	gelb
...

Färbeproblem

Es scheint sinnvoller zu sein, die Länder der Reihe nach zu färben.

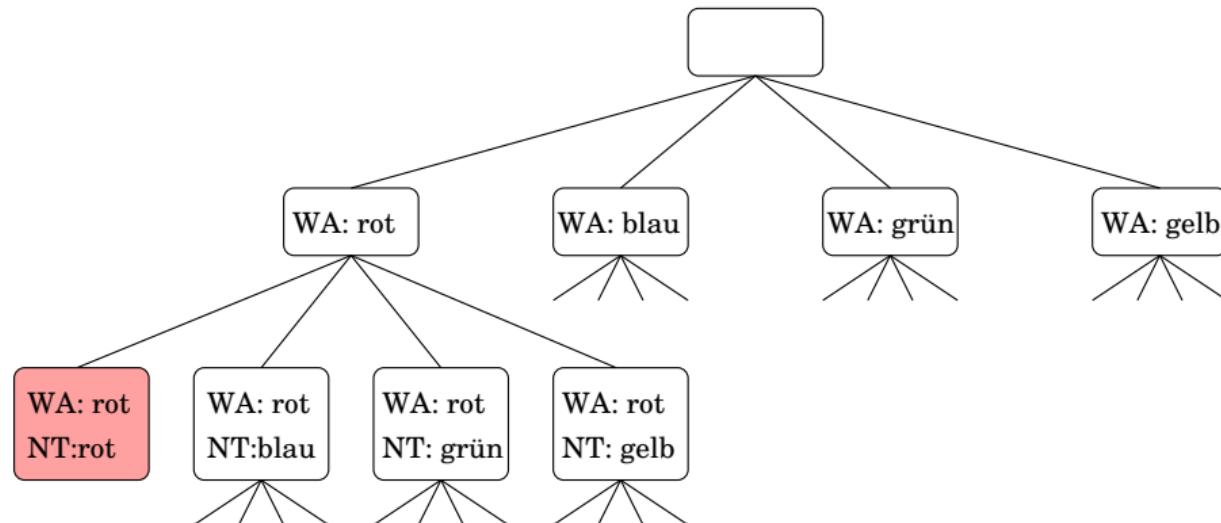


- Die Problemlösung startet mit der leeren Färbung () .
- Ziel ist es, eine komplette, zulässige Färbung zu erreichen.
- Die Schritte im Laufe der Problemlösung lassen sich durch Zustandsübergangsoperatoren beschreiben.

- Beschreibe Zwischenzustände durch Teilfärbungen, etwa (WA:rot, NT:blau, SA:gelb).
- Nach der teilweisen Zuordnung (WA:blau, NT:blau) wird direkt abgebrochen, da die Länder benachbart sind.

Die Lösung des Färbeproblems lässt sich als Suchbaum darstellen:

- Knoten entsprechen den Zuständen (zulässige Teilstufen).
- Kanten entsprechen den Operatoren.



- Ungültige Teillösungen werden nicht weiter verfolgt.

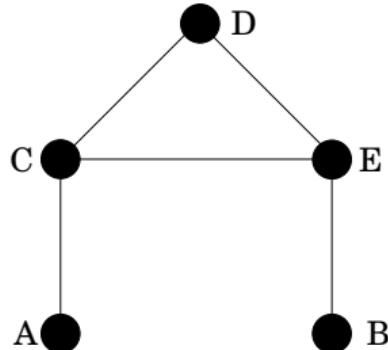
Für Suchprobleme lässt sich das Wissen wie folgt repräsentieren:

- Ein Zustand repräsentiert das Wissen zu einem bestimmten Zeitpunkt der Lösungsfindung.
- Die Menge aller Zustände ist der Zustandsraum.
- Zustandsübergangsoperatoren beschreiben den Wechsel von einem Zustand zu einem anderen Zustand des Zustandsraums.
- Den Zustand zu Beginn der Lösungsfindung nennt man Startzustand, er lässt sich explizit angeben.
- Die Menge der Zielzustände charakterisiert die Lösungen des Problems.
- Zielzustände lassen sich oft nur implizit angeben, z.B. über ein Testprädikat.
- Um verschiedene Lösungen vergleichen zu können, können Folgen von Aktionen Kosten zugewiesen werden.

Typischerweise definiert man Kosten abhängig von einem Zustand und einer Aktion. Die Gesamtkosten für eine Aktionenfolge ergeben sich aus den Einzelkosten.

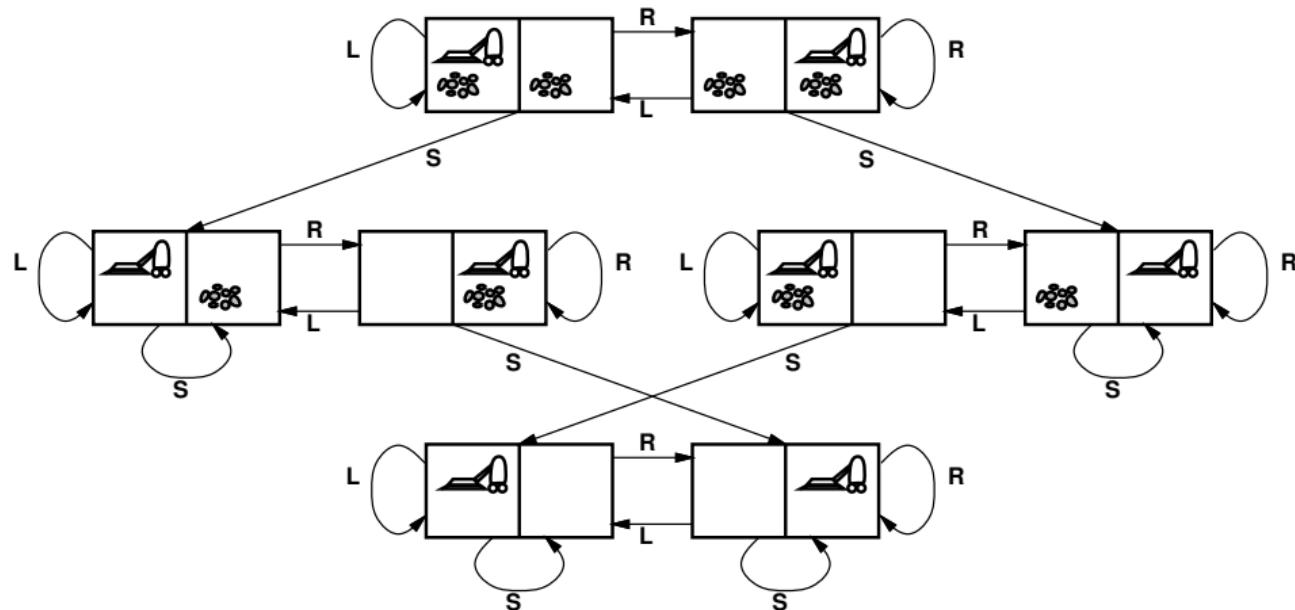
Gegeben ist eine Karte mit Städten und Straßen, die die Städte miteinander verbinden.

Gesucht ist eine Route von einem Startort zu einem Zielort.



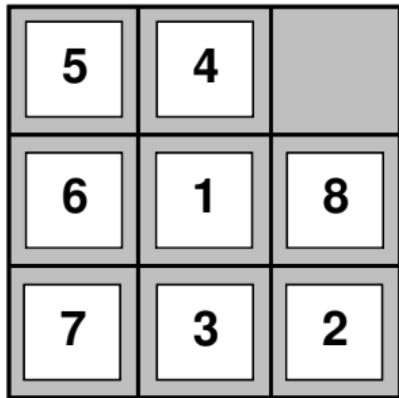
Übung 12.

- Erstellen Sie den Suchbaum zu obigen Beispiel für den Fall, dass Sie eine Route von A nach B finden wollen.
- Wie können Sie verhindern, dass die Route Kreise enthält?

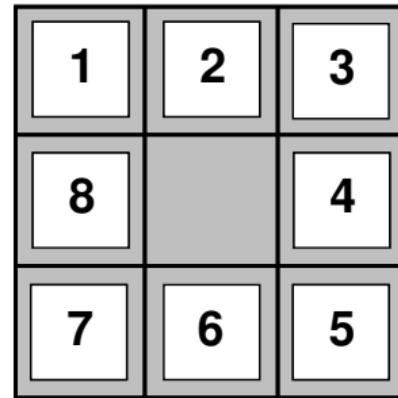


- *Operationen*: rechts, links, saugen
- *Ziel*: alle Räume müssen sauber sein

8-Puzzle



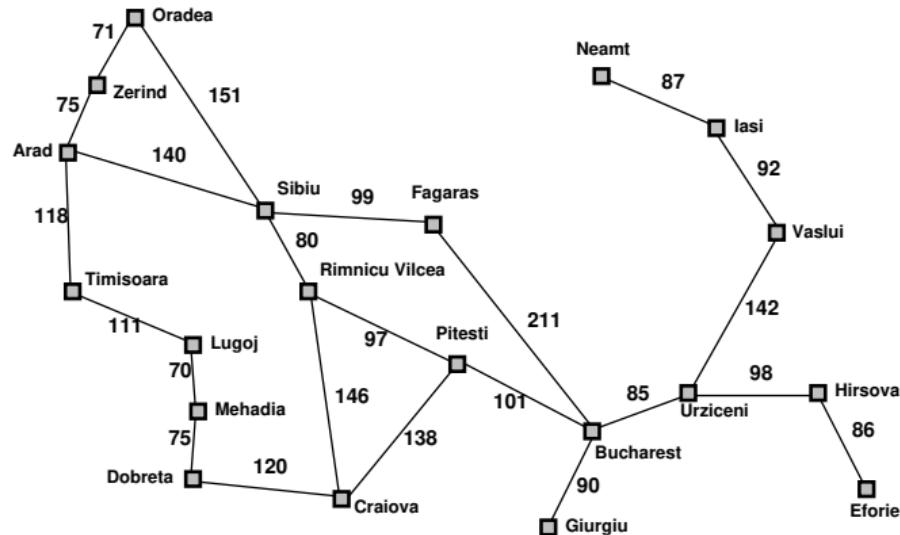
Start State



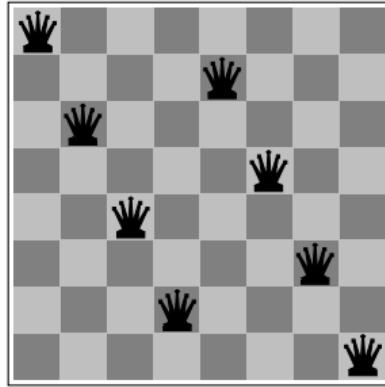
Goal State

- *Operationen*: schiebe das leere Feld nach rechts, links, oben oder unten
- *Ziel*: Endkonfiguration

Routenplanung



- **Operationen:** Gehe von einer Stadt zu einer benachbarten Stadt entlang einer Kante.
- **Ziel:** Der kürzeste Weg vom Start zum Ziel ist berechnet.
- Der Zielzustand ist hier nicht explizit bekannt. Wie sieht in diesem Fall das Testprädikat aus?



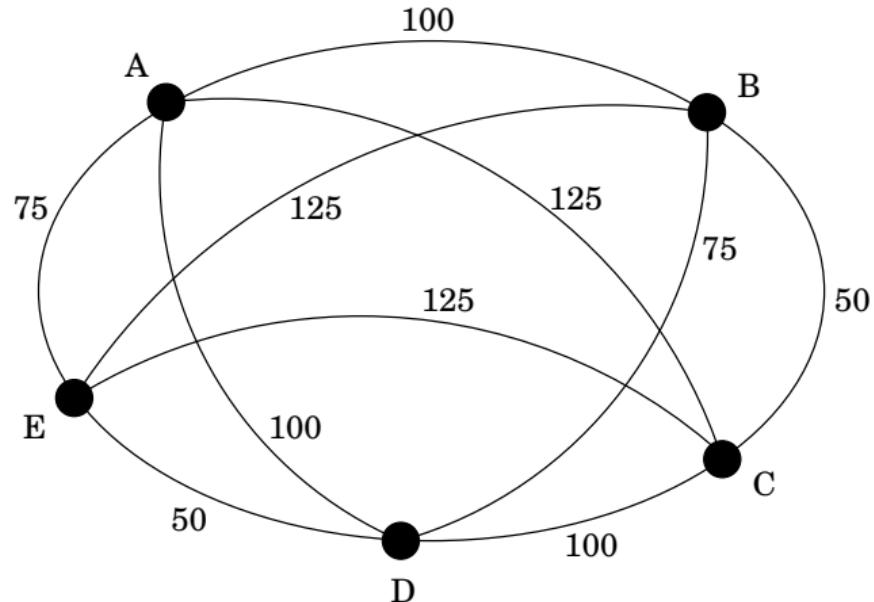
- *Zustand*: Plazierung zwischen 0 und 8 Damen.
- *Operationen*: Eine Dame plazieren.
- *Ziel*: Alle Damen sind so plaziert, dass sie sich nicht gegenseitig bedrohen.

Übung 13.

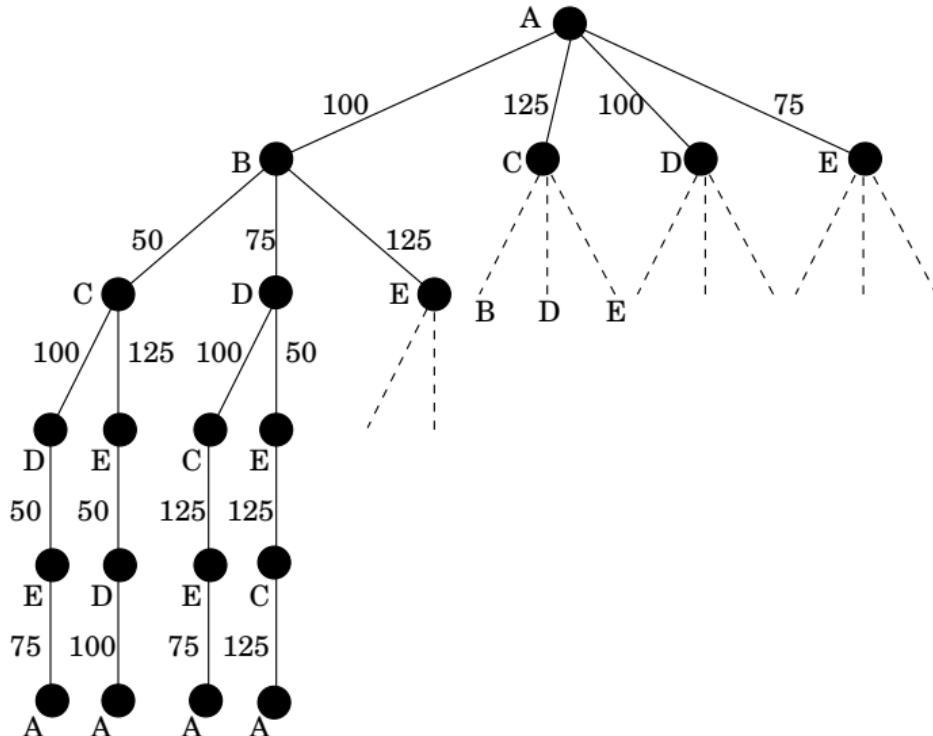
- Auch bei diesem Problem sind die Endzustände nicht explizit bekannt. Wie sieht hier das Testprädikat aus?
- Implementieren Sie eine Zustandsraumsuche und ein naives generate-and-test Verfahren und vergleichen Sie die Lösungen.
- Wie kann der Suchraum verkleinert werden? Bringt das signifikante Laufzeitvorteile?

Problem des Handlungsreisenden

Finde den kürzesten Reiseweg, der genau einmal durch alle Städte führt und wieder bei der ersten Stadt endet.



Problem des Handlungsreisenden



Da die Stadt, in der die Rundreise beginnt, festgelegt ist, hat die erschöpfende Suche bei n Städten eine Komplexität von $(n - 1)!$.

Reduktion der Suchkomplexität durch *Branch-and-Bound*:

- Generiere zu einem Zeitpunkt jeweils nur einen Weg.
- Die Kosten des bisher besten Weges wird als Schranke bei weiteren Kandidaten eingesetzt.
- Ist ein Teilweg bereits teurer als die bisher beste Lösung, so werden alle Erweiterungen des Weges nicht weiter betrachtet.
- Weitere Reduktion durch Schätzen der verbleibenden Kosten:
 - Jede der noch nicht besuchten Städte muss besucht und auch wieder verlassen werden.
 - Addiere jeweils die Werte der zwei kostengünstigsten Kanten, die inzident zu einem noch unbesuchten Knoten sind.
 - Die Summe muss noch durch 2 dividiert werden, da jede Kante zweimal genutzt wird: um einen Knoten zu verlassen und um den nächsten zu besuchen.

→ Komplexität: 1.26^n , leider immer noch exponentiell!

Die Berechnung der Nachfolger eines Knotens s wird als *Expansion* des Knotens s bezeichnet.

Der Zustandsraum beschreibt lediglich, *wie* man zu einer Lösung gelangen kann, aber nicht, *wie* man effizient zu dieser kommt.

Wesentlich für eine effiziente Problemlösung sind:

- Die Reihenfolge, in der die Zustände untersucht bzw. expandiert werden
- sowie die Bewertung der einzelnen Zustände.

1 Übersicht

- Informierte Suchverfahren
- Lokale Suche
- Spiele

2 Geschichte und Anwendungen

3 Wissensrepräsentation

4 Zustandsraumsuche

- Uninformierte Suche

5 Aussagenlogik

6 Prädikatenlogik

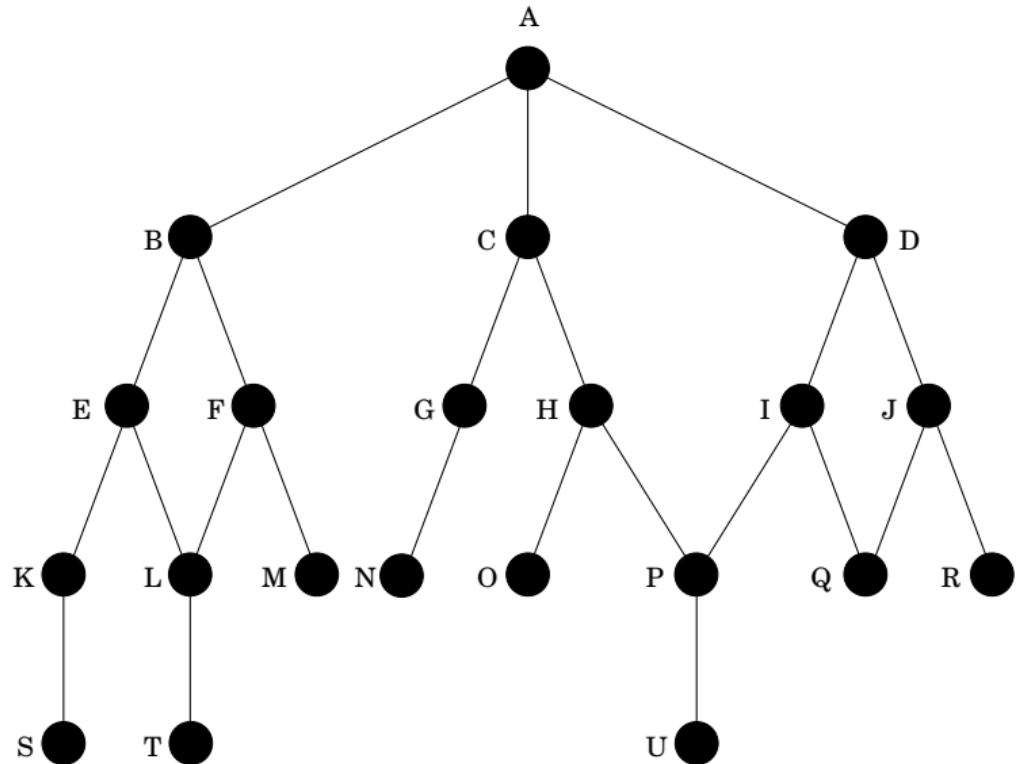
7 Prolog

- Suchverfahren, die über die Beschreibung des Zustandsraums hinaus keine Zusatzinformation benutzen.
- Insbesondere findet keine Bewertung der einzelnen Zustände statt. Um Wiederholungen zu vermeiden, werden bereits untersuchte Zustände markiert oder gespeichert.
- Die Verfahren unterscheiden sich im wesentlichen darin, in welcher Reihenfolge die Zustände expandiert werden.
- Die wichtigsten Vertreter der uninformierten Suchverfahren sind die *Breitensuche* und die *Tiefensuche*.
- Ausgehend von der Wurzel des Suchbaums (Startzustand) werden die Knoten sukzessive expandiert.
- Später wird von den Nachfolgern des expandierten Knotens weiter gearbeitet, solange bis ein Zielknoten gefunden wurde.

Breiten- und Tiefensuche laufen nach dem gleichen Schema ab:

- **Agenda**: Liste der Knoten, die gerade in Bearbeitung sind.
- Knoten der Agenda sind generiert, aber noch nicht expandiert.
- Zu Beginn der Suche besteht die Agenda nur aus dem Startzustand.
- In einer beliebigen Iteration wird der erste Knoten s_{akt} aus der Agenda genommen.
- Wenn s_{akt} ein Zielzustand ist, hat man eine Lösung gefunden.
- Ist s_{akt} kein Zielzustand, so wird s_{akt} expandiert, d.h. alle Nachfolger von s_{akt} werden in die Agenda eingefügt.
- Breiten- und Tiefensuche unterscheiden sich darin, wo die Nachfolger in die Agenda eingefügt werden.

Beispiel für Tiefen- und Breitensuche



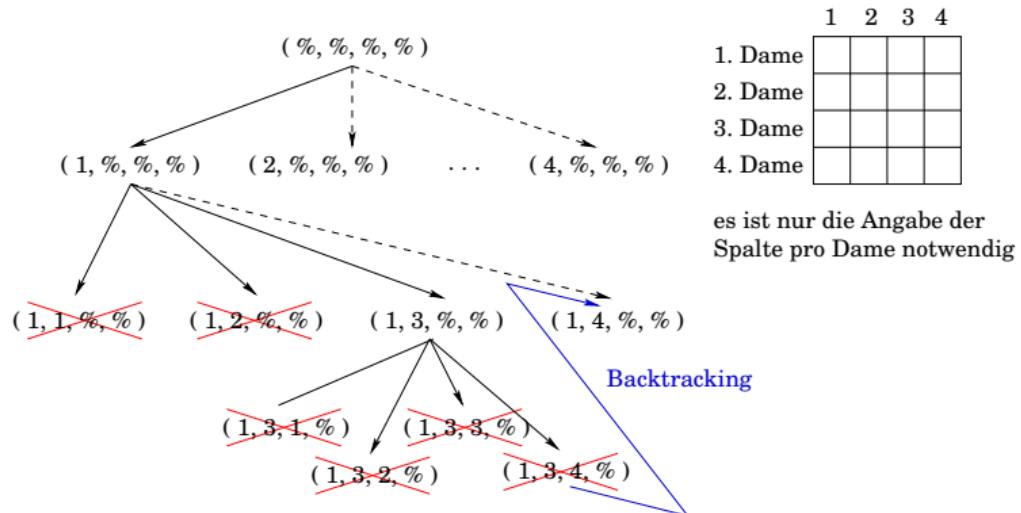
Tiefensuche

Bei der Tiefensuche werden die Nachfolger eines expandierten Knotens an den Anfang der Agenda eingefügt. Die Agenda entspricht einem Kellerspeicher (Stack).

```
Node * DFsearch(Node * pRoot) {
    Stack<Node *> agenda;      // Tiefensuche
    agenda.push(pRoot);
    while (not agenda.isEmpty()) {
        Node *pCurr = agenda.pop();
        if (zielknoten(pCurr))
            return pCurr;
        for (Node *n : nachfolger(pCurr))
            agenda.push(n);
    }
    return null;
}
```

Tiefensuche

- Liefert ein Knoten, der kein Zielknoten ist, keine neuen Knoten, so wird die Suche fortgesetzt an dem nächstgelegenen Knoten, für den noch nicht alle Nachfolger expandiert wurden.
- Das Verhalten entspricht einem Backtracking (zurückverfolgen).

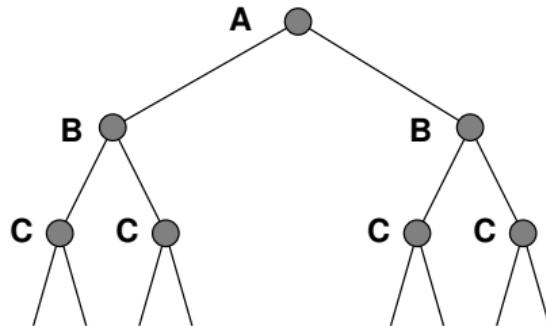
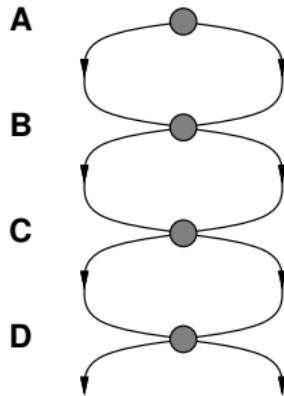


- Die Abarbeitung wird an den Knoten abgebrochen, die zu keiner zulässigen Lösung führen können.

Repeated States

Wie verhindern wir, dass Zustände wiederholt untersucht werden?

- Problem tritt immer dann auf, wenn Operationen umkehrbar sind: Schiebepuzzle, Routenproblem, Spiele, usw.
- Wird nicht erkannt, das Zustände bereits untersucht wurden, kann aus einem linearen Problem ein exponentielles werden:



- Der einzige Weg, wiederholtes Untersuchen von Zuständen zu vermeiden, ist: Speichere bereits besuchte Zustände. → Tradeoff between space and time!

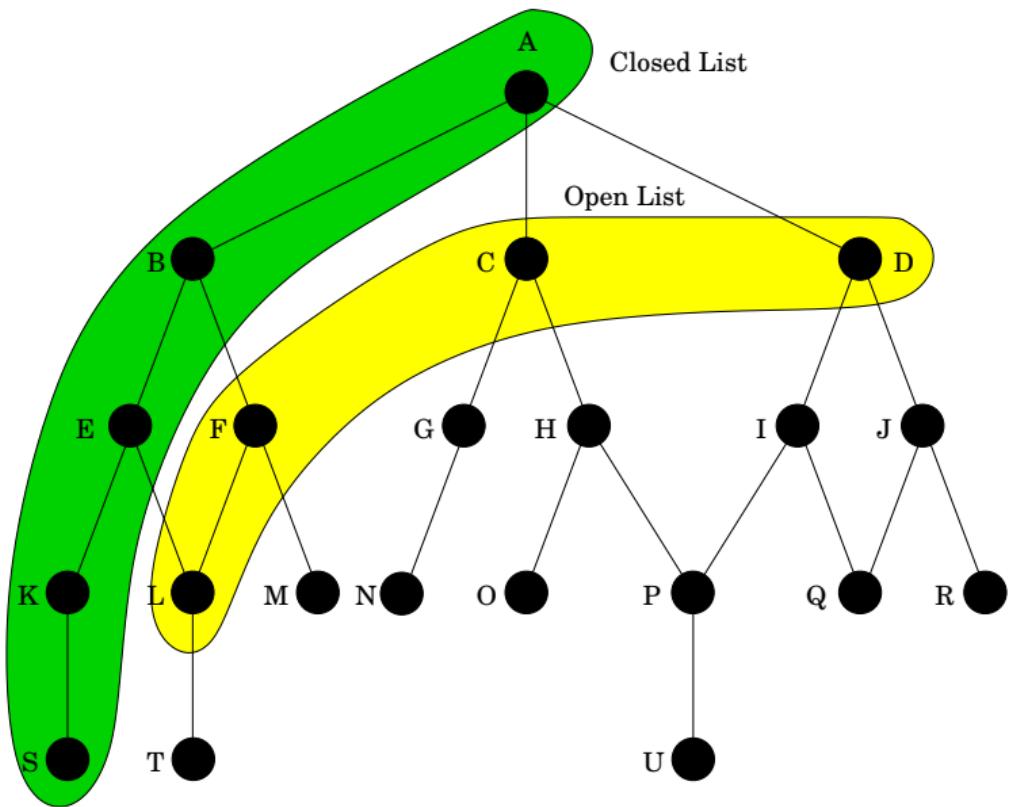
- *Algorithms that forget their history are doomed to repeat it.*
- Um die bereits untersuchten Zustände zu speichern, werden expandierte Knoten in der *closed list* verwaltet.
- Wenn der aktuell zu untersuchende Zustand bereits in der closed list gespeichert ist, wird er verworfen anstatt expandiert zu werden.
- Die Agenda wird daher auch *open list* genannt.

Tiefensuche

Die um eine Closed-List erweiterte Tiefensuche zur Vermeidung wiederholter Zustände:

```
Node * search(Node * pRoot) {
    Stack<Node *> openList;      // Tiefensuche
    openList.push(pRoot);
    HashSet<Node *> closedList;
    while (not openList.isEmpty()) {
        Node *pCurr = openList.pop();
        if (zielknoten(pCurr))
            return pCurr;
        if (not closedList.contains(pCurr)) {
            closedList.insert(pCurr);
            for (Node *n : nachfolger(pCurr))
                openList.push(n);
        }
    }
    return null;
}
```

Tiefensuche

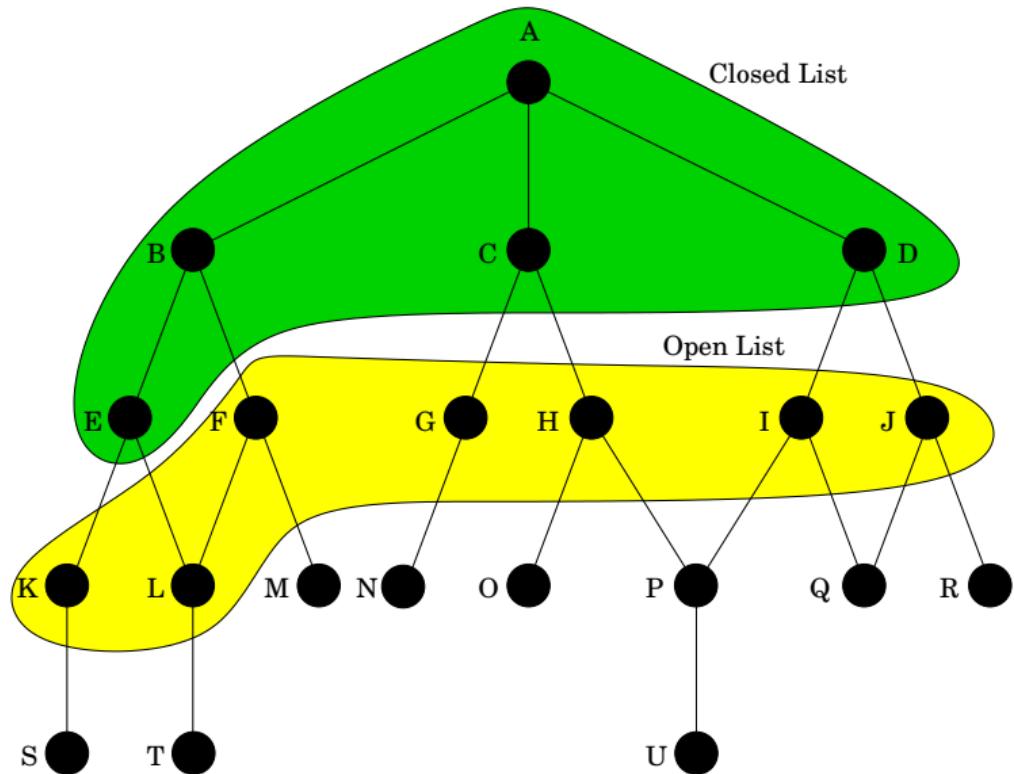


Breitensuche

Bei der Breitensuche werden die Nachfolger eines expandierten Knotens an das Ende der Agenda eingefügt. Die Agenda entspricht einer Warteschlange (Queue).

```
Node * BFsearch(Node * pRoot) {
    Queue<Node *> openList;      // Breitensuche
    openList.push(pRoot);
    HashSet<Node *> closedList;
    while (not openList.isEmpty()) {
        Node *pCurr = openList.pop();
        if (zielknoten(pCurr))
            return pCurr;
        if (not closedList.contains(pCurr)) {
            closedList.insert(pCurr);
            for (Node *n : nachfolger(pCurr))
                openList.push(n);
        }
    }
    return null;
}
```

Breitensuche



Übung 14. Ein Weinhändler hat drei Krüge mit 9l, 7l bzw. 4l Inhalt.

- Auf den Krügen sind keine Litermarkierungen angebracht.
- Der 9l-Krug ist gefüllt, die anderen beiden sind leer.
- Die Krüge sollen so umgefüllt werden, dass der 9l-Krug sechs Liter und der 4l-Krug drei Liter enthält.

Erstellen Sie den Suchbaum und ermitteln Sie mittels Tiefen- und Breitensuche eine Lösung des Problems.

Übung 15. Betrachten Sie das Kannibalen und Missionare-Problem:

- 3 Missionare und 3 Kannibalen wollen einen Fluss überqueren.
- Es steht nur ein Ruderboot für die Überfahrt zur Verfügung.
- Das Boot kann maximal 2 Personen aufnehmen.
- Es dürfen nie mehr Kannibalen als Missionare an einem Ort sein, sonst gibt es ein großes Fressen.

Aufgabe:

- Definieren Sie die Zustandsmenge und die Operatoren, die einen Zustand in einen anderen Zustand überführen.
- Erstellen Sie den Suchbaum und ermitteln Sie mittels Tiefen- und Breitensuche eine Lösung des Problems. Zustände, bei denen mehr Kannibalen als Missionare an einem Ort sind, werden nicht weiter verfolgt.

Ungünstiger Fall für Breiten- und Tiefensuche: Die Lösung liegt in der „äußersten, unteren rechten Ecke“ des Suchbaums.

- Sei b die Verzweigungsrate und
- sei t die Tiefe des Zielknotens.

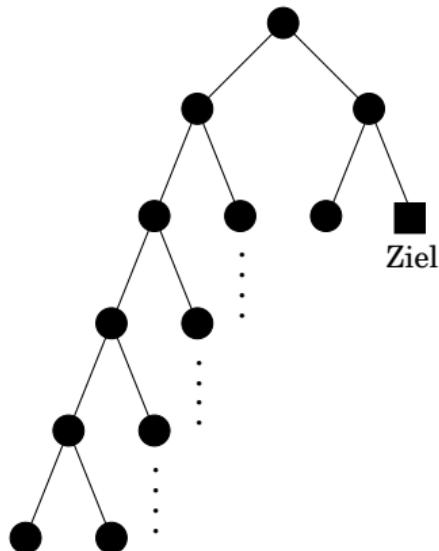
Breitensuche: Die Agenda kann eine komplette Ebene des Suchbaums enthalten, daher erhalten wir:

- Zeitkomplexität: $\Theta(b^t)$
- Platzkomplexität: $\mathcal{O}(b^t)$

Tiefensuche: Sei m die maximale Tiefe des Baums.

- Platzkomplexität: $\mathcal{O}(b \cdot m)$, denn die Agenda enthält nur die Knoten des aktuellen Suchpfades sowie deren Nachfolger.
- Zeitkomplexität: $\mathcal{O}(b^m)$

Laufzeit Tiefensuche: $\mathcal{O}(b^m)$



$b = 2$ (Verzweigungsrate)
 $m = 5$ (Tiefe des Baums)
 $t = 2$ (Tiefe des Ziels)

Eine Breitensuche würde das Ziel viel schneller finden. Leider ist bei vielen Problemen keine Breitensuche einsetzbar, z.B. bei Schach oder Go, da dort die Verzweigungsrate zu hoch ist!

Ein Suchverfahren heißt *vollständig*, wenn für jeden Suchbaum jeder Knoten expandiert werden könnte, solange noch kein Zielknoten gefunden wurde.

- Ein vollständiges Suchverfahren ist fair in dem Sinne, dass jeder Knoten die Chance hat, expandiert zu werden.
- Ein vollständiges Suchverfahren findet auch bei unendlichen Suchbäumen stets eine Lösung, falls eine existiert.

Nach dieser Definition gilt: Die Breitensuche ist vollständig.

- Tiefensuche ist nur bei endlichen Suchbäumen vollständig. Hat ein Zweig im Suchbaum unendliche Tiefe, dann können Knoten in anderen Zweigen nicht expandiert werden.

Für ein uninformiertes Suchverfahren heißt eine Lösung *optimal*, wenn sie unter allen Lösungen die geringste Tiefe im Suchbaum aufweist. Nach dieser Definition gilt:

- Die Breitensuche findet eine optimale Lösung, falls eine Lösung existiert.
- Eine Tiefensuche findet im Allgemeinen keine optimale Lösung.

Tiefensuche mit Begrenzung der Suchtiefe

Wir versuchen, die Nachteile der Tiefensuche auszuschalten, indem wir eine maximale Suchtiefe vorgeben:

- Zweige jenseits der maximalen Suchtiefe werden abgeschnitten.
- Dadurch wird garantiert, dass eine Lösung gefunden wird, wenn eine innerhalb der Suchtiefe existiert.

Frage: Stimmt das so ohne Weiteres? Was ist mit den in der Closed-List gespeicherten Zuständen?

- Nachteil: Wie groß soll man die maximale Suchtiefe wählen?

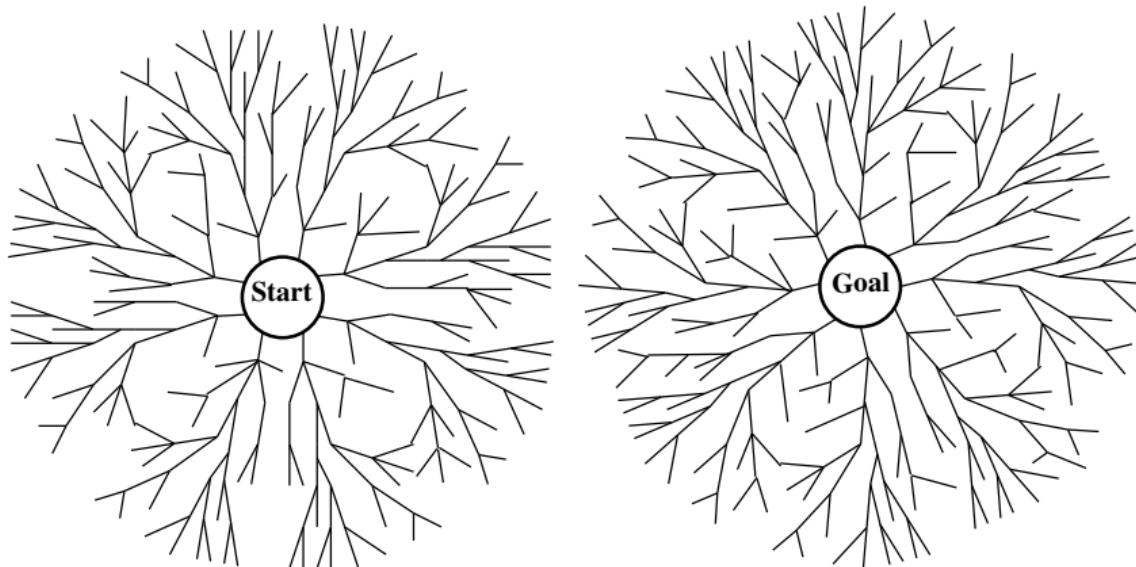
Da man nicht weiß, wie groß man die maximale Suchtiefe wählen soll, probiert man dies einfach systematisch durch: schrittweise vertiefende Suche

- Führe immer wieder eine Tiefensuche mit Begrenzung der Suchtiefe durch und erhöhe nach einer erfolglosen Suche die maximale Suchtiefe jeweils um eins.
- Bei einer maximalen Suchtiefe t und einem regulären Suchbaum mit Verzweigungsgrad b werden $\mathcal{O}(b^t)$ Knoten erzeugt.
- Man verliert bei diesem Verfahren nur einen konstanten Faktor⁽⁵⁸⁾:

$$\sum_{d=0}^t b^d = \frac{b^{t+1} - 1}{b - 1} < \frac{b}{b - 1} b^t = \mathcal{O}(b^t)$$

⁽⁵⁸⁾dies gilt nur, falls der Verzweigungsgrad konstant ist, also die Suche einen exponentiellen Zeitaufwand hat

- Gleichzeitige Suche vom Start zum Ziel und vom Ziel zum Start.
- Lösungen ergeben sich dort, wo sich die Suchpfade treffen.



Durch Halbierung der Länge der Suchpfade ergibt sich ein Aufwand⁽⁵⁹⁾ von $\mathcal{O}(2b^{\frac{d}{2}}) = \mathcal{O}(b^{\frac{d}{2}})$.

⇒ Drastische Reduzierung der Laufzeit! Die in akzeptabler Zeit lösbar Problemgröße kann verdoppelt werden.

Probleme:

- Zielzustände sind oft nicht explizit bekannt: n -Damen-Problem
- Zielzustände müssen nicht eindeutig sein: n -Damen-Problem
- Operatoren sind nicht unbedingt umkehrbar.

Übung 16. Implementieren Sie eine bidirektionale Suche für Brett-Solitär. Ergibt sich eine signifikante Verbesserung der Laufzeit gegenüber Ihrem ursprünglichen Programm?

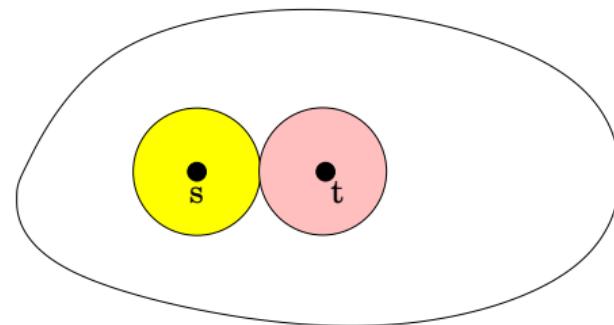
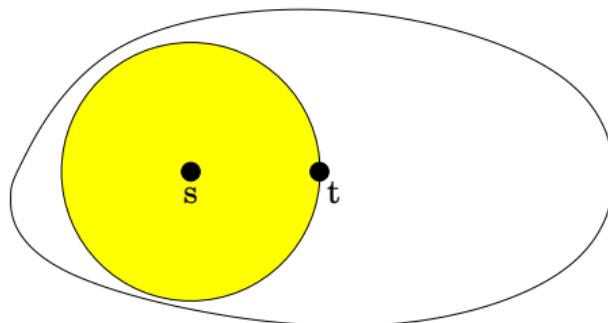
⁽⁵⁹⁾dies gilt nur, falls der Verzweigungsgrad konstant ist, also die Suche einen exponentiellen Zeitaufwand hat

Bidirektionale Suche

Bei der Routenplanung mittels Dijkstras Algorithmus kann die Berechnung durch die bidirektionale Suche nur um den Faktor 2 beschleunigt werden.

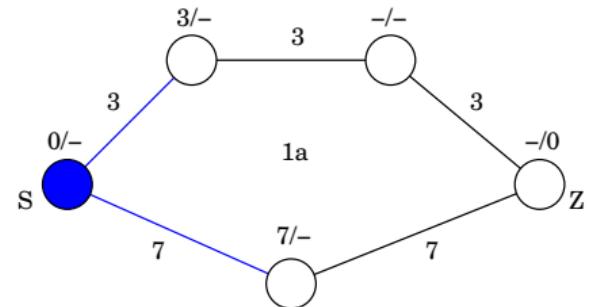
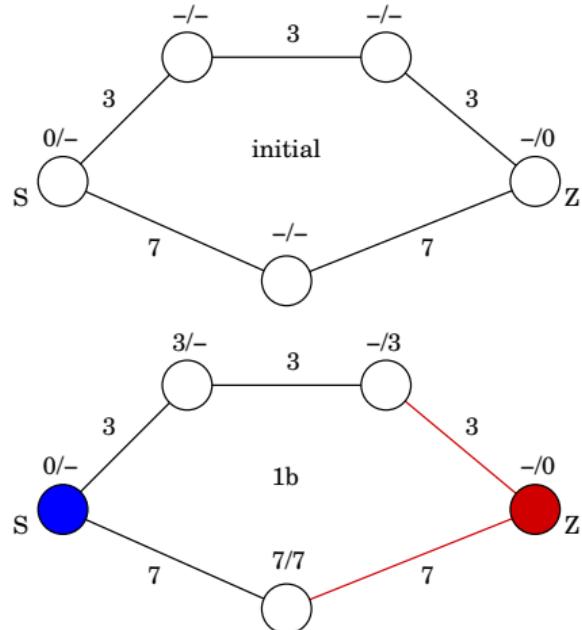
bisher: $d(s, t)^2 \cdot \pi$

jetzt: $2 \cdot \left(\frac{d(s, t)^2}{4} \cdot \pi \right)$



Bidirektionale Suche

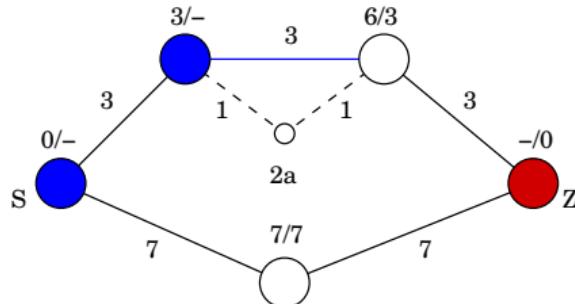
Außerdem darf bei der Routenplanung die Suche nicht dann abgebrochen werden, wenn sich zwei Suchpfade treffen.



Die Suchpfade treffen sich zwar in dem unteren Knoten, aber der kürzeste Weg wurde noch nicht gefunden.

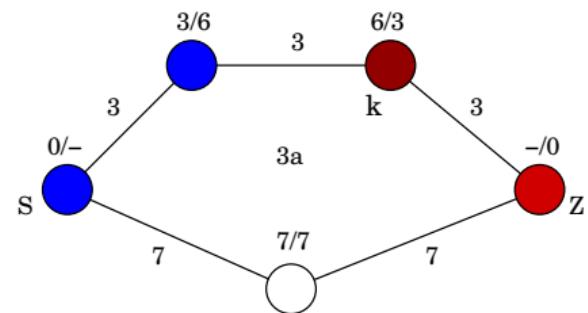
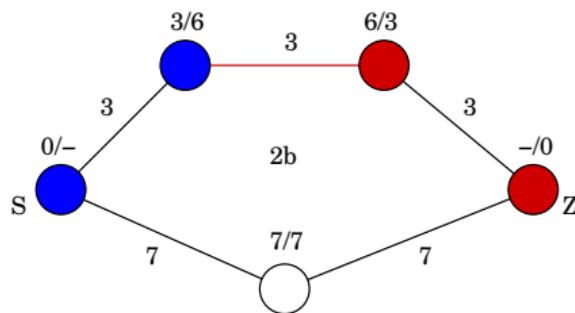
Die Suche wird also fortgesetzt.

Bidirektionale Suche



Auch hier darf die Suche noch nicht abgebrochen werden, denn es könnte noch einen kürzeren Weg geben.

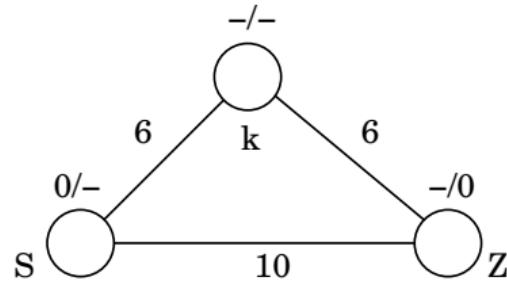
Die Suche wird also fortgesetzt.



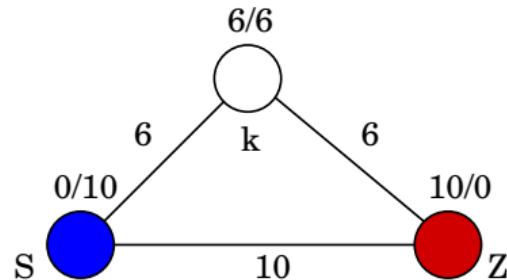
Erst wenn ein Knoten k von beiden Suchrichtungen aus als final markiert wurde, kann die Suche abgebrochen werden.

Frage: Ist k auf kürzesten Weg vom Start zum Ziel enthalten?

Nein! Ein Knoten k , der von beiden Suchrichtungen aus als final markiert wurde, muss nicht notwendig auf einem kürzesten Weg vom Start zum Ziel enthalten sein.



Bei beiden Suchrichtungen wird im ersten Schritt jeweils die Distanz zum Knoten k auf den Wert 6 aktualisiert.

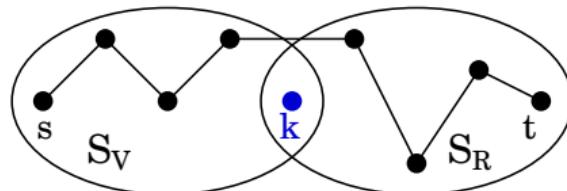
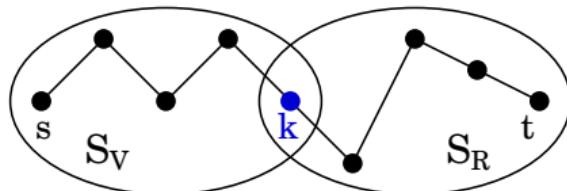


Im nächsten Schritt wird jeweils der Knoten k ausgewählt und aus der Priority-Queue entfernt. Aber k liegt nicht auf dem kürzesten Weg vom Start S zum Ziel Z .

Aber: Der kürzeste Weg wurde korrekt berechnet, sobald ein Knoten k gefunden wurde, der von beiden Suchen als final markiert wurde.

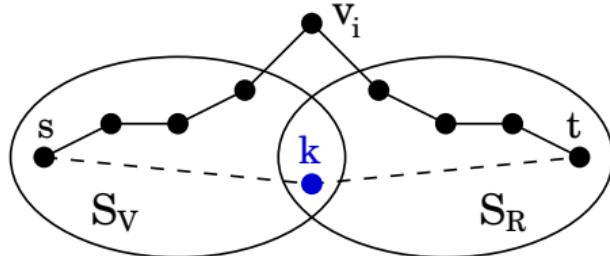
- natürlich gilt: $\overleftarrow{d[v]} + \overrightarrow{d[v]} \geq dist(s, t)$
- Seien S_V und S_R die abgearbeiteten Knoten der Vorwärts- bzw. Rückwärtssuche nach Terminierung.
- Sei $P = (v_1, \dots, v_m)$ ein kürzester Weg vom Start zum Ziel.
- zeige:

- $\{v_1, \dots, v_m\} \subseteq S_V \cup S_R$ oder



- $|P| = dist(s, k) + dist(k, t)$

- Angenommen, es gibt ein $v_i \notin S_V \cup S_R$



- Dann gilt $dist(s, v_i) \geq dist(s, k)$ und $dist(v_i, t) \geq dist(k, t)$, da sonst Dijkstra Knoten v_i ausgewählt hätte und nicht k .
- Also ist $|P| = dist(s, v_i) + dist(v_i, t) \geq dist(s, k) + dist(k, t)$.
- Da P nach Voraussetzung ein kürzester Weg ist, muss gelten:
 $|P| = dist(s, v_i) + dist(v_i, t) = dist(s, k) + dist(k, t)$

1 Übersicht

- **Informierte Suchverfahren**

- Lokale Suche

- Spiele

2 Geschichte und Anwendungen

3 Wissensrepräsentation

4 Zustandsraumsuche

- Uninformierte Suche

5 Aussagenlogik

6 Prädikatenlogik

7 Prolog

- Für größere Suchbäume sind Breiten- und Tiefensuche nicht effizient genug.
- Vielversprechender sind Ansätze, bei denen Problemwissen zur Steuerung des Suchprozesses eingesetzt wird.
- Dies kann dadurch geschehen, dass die Zustände (Knoten) danach bewertet werden, wie erfolgversprechend sie sind.
- Man schätzt bspw. für jeden Knoten, wie nahe er an einem Zielknoten liegt.
- Solch eine Bewertung nennt man heuristische Funktion.
 - griech. eurisco heißt „ich entdecke“
 - „Heureka“: ich habe es gefunden
- Heuristik bei Zustandsraumsuche: Regeln zur Auswahl solcher Zweige, die mit hoher Wahrscheinlichkeit zu einer akzeptablen Problemlösung führen.

Wir lernen die Zustandsraumsuche im wesentlichen bei Spielen kennen, weil

- die Suchräume groß genug sind, um eine heuristische Beschneidung (engl. Pruning) zu erfordern.
- die meisten Spiele komplex genug sind, so dass eine Vielzahl heuristischer Bewertungen für den Vergleich und die Analyse einsetzbar sind.
- Spiele i.Allg. keinen komplexen Repräsentationsaufwand erfordern, so dass man sich auf das Verhalten der Heuristik statt auf Probleme der Wissensrepräsentation konzentrieren kann.
- alle Knoten des Zustandsraums eine gemeinsame Repräsentation besitzen, so dass im gesamten Suchraum eine einzige Heuristik angewendet werden kann.

Wann werden informierte Suchverfahren eingesetzt?

- Wenn ein Problem keine exakte Lösung hat, weil bspw. die Problembeschreibung oder die verfügbaren Daten zweideutig sind.
 - Medizinische Diagnose: Eine Menge von Symptomen kann verschiedene Ursachen haben.
 - Wähle die wahrscheinlichste Lösung.
 - Visuelle Wahrnehmung: Optische Täuschung, Ausrichtung oder Orientierung von Objekten nicht klar.
 - Wähle die wahrscheinlichste Interpretation der Szene.
- Wenn die Rechenkosten für die Suche nach einer exakten Lösung zu groß sind, weil die Anzahl der Zustände exponentiell oder faktoriell mit der Tiefe der Suche wächst, wie z.B. bei Schach oder Go.
- Suche entlang eines „viel versprechenden“ Weges.

Anwendungen:

- Spiele: Es kann nicht jede erreichbare Spielsituation beim Schach (Verzweigungsgrad⁽⁶⁰⁾ etwa 35, Anzahl Züge etwa 80) oder Go (Verzweigungsgrad⁽⁶¹⁾ etwa 235, Anzahl Züge bei Profis etwa 250 bis 300) weiterverfolgt werden.
- Theorembeweise: Es kann nicht jede Schlussfolgerung weiterverfolgt werden.

Expertensysteme:

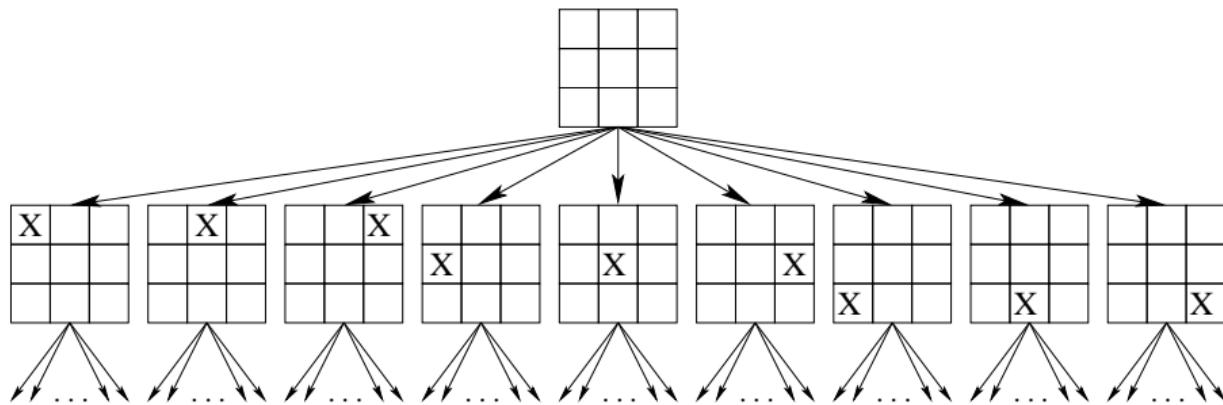
- Heuristiken sind essentielle Komponenten von Problemlöseverfahren.
- Menschliche Experten verwenden Faustregeln.
- Faustregeln sind weitgehend heuristisch.

→ Extrahiere und formalisiere Faustregeln.

⁽⁶⁰⁾Chess Programming Wiki, https://www.chessprogramming.org/Branching_Factor

⁽⁶¹⁾Willmott, Richardson, Bundy, Levine. Applying adversarial planning techniques to Go. Theoretical Computer Science, 252(1), 2001

Tic-Tac-Toe ohne Heuristik:

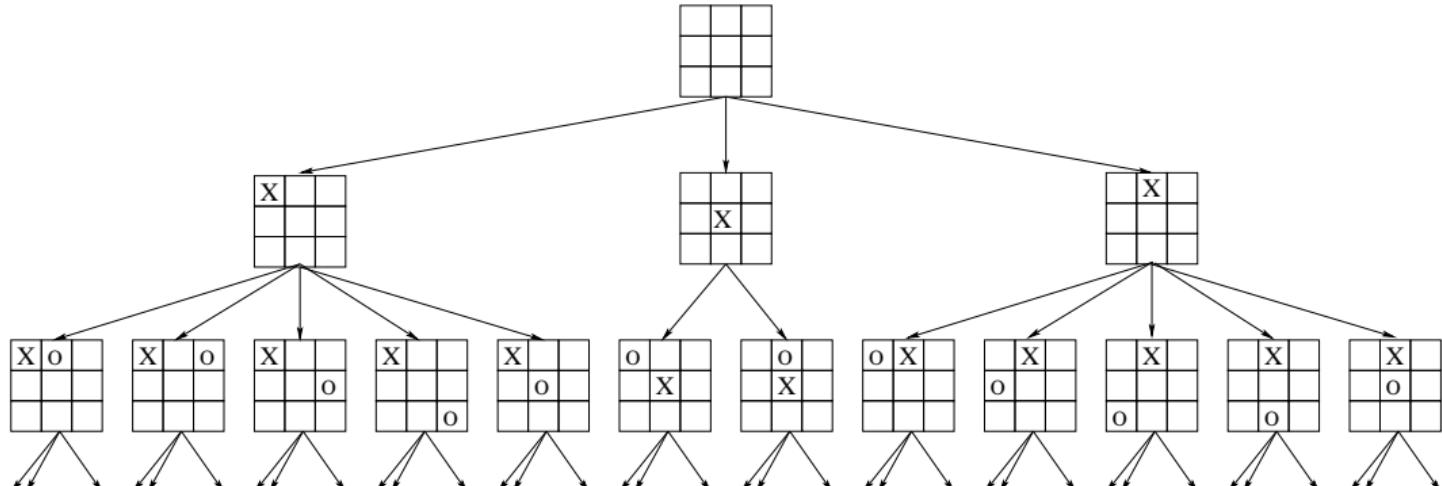


$$\Rightarrow 9! = 9 \cdot 8 \cdot 7 \cdot \dots \cdot 2 \cdot 1 = 362.880 \text{ mögliche Zustände}$$

Beachte: Viele doppelte Zustände durch Zuggenerierung. Es gibt weniger als $3^9 = 19.683$ verschiedene Zustände!

\Rightarrow Es scheint sinnvoll zu sein, bereits untersuchte Zustände in einer Hash-Tabelle zu verwalten.

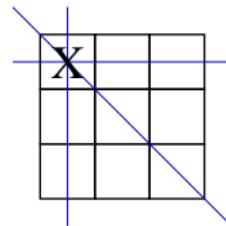
Reduktion bzgl. Symmetrien bei Tic-Tac-Toe:



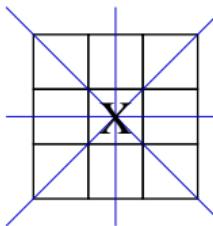
$$\Rightarrow 12 \cdot 7! = 60.480 \text{ mögliche Zustände}$$

Problem: Wie baut man einen Zuggenerator, der Symmetrien berücksichtigt?

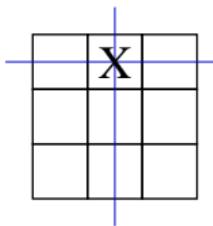
Heuristik der „meisten Gewinnmöglichkeiten“ bei Tic-Tac-Toe:



Anzahl Gewinn-
möglichkeiten 3



4

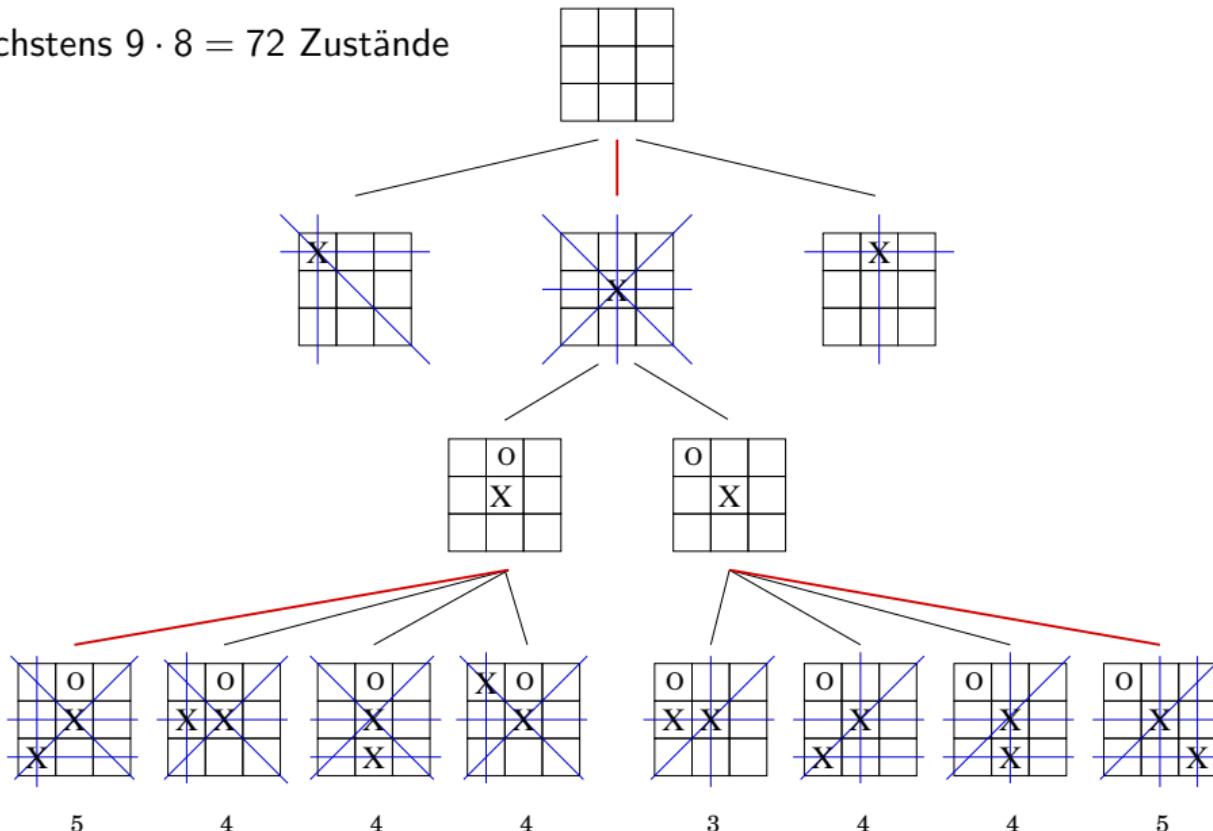


2

Wir beschränken also die Suche auf die Nachfolgezustände des obigen, mittleren Zustands. Anschließend wenden wir noch die Reduktion bzgl. Symmetrien an.

Informierte Suchverfahren

⇒ höchstens $9 \cdot 8 = 72$ Zustände

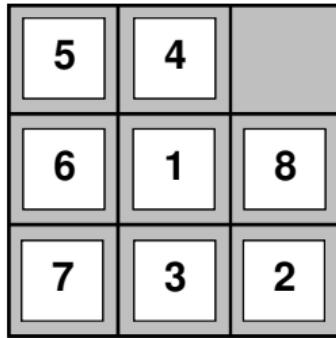


Eine Funktion, die jedem Zustand (Knoten) s eines Zustandsraums (Suchbaums) eine nichtnegative Zahl $h(s)$ zuordnet, heißt *heuristische Funktion*. Für einen Zielzustand s gilt dabei $h(s) = 0$.

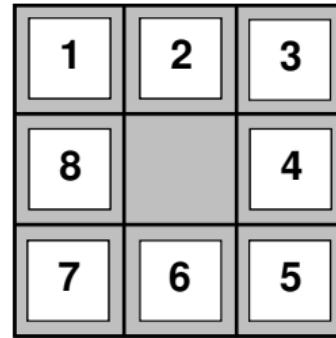
- Die heuristische Funktion schätzt für jeden Knoten, wie „nahe“ der Knoten am Zielzustand liegt bzw. wie viele Operationen bis zum Erreichen des Ziels noch notwendig sind. Bei der Auswahl der Knoten werden solche Knoten bevorzugt, die „nahe“ am Ziel liegen.
- Reduktion der besuchten Knoten

Ein Suchverfahren, das eine heuristische Funktion zur Auswahl der zu expandierenden Zustände einsetzt, heißt *informiertes Suchverfahren* oder auch *heuristisches Suchverfahren*.

Beispiel Schiebepuzzle:



Start State

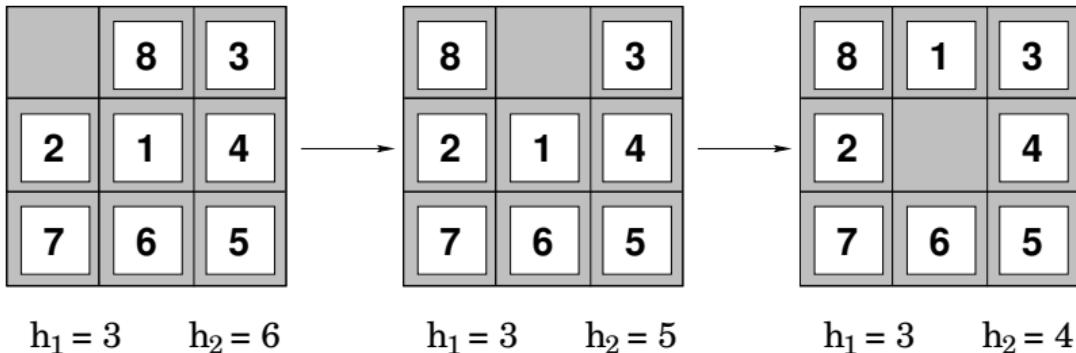


Goal State

Mögliche heuristische Funktionen:

- $h_1(s)$: Anzahl der Plättchen, die nicht an der richtigen Stelle liegen. Hier:
$$h_1(s) = 7$$
- $h_2(s)$: Summe der Entfernungen aller Plättchen von der Zielposition, also die Manhatten-Distanz. Hier:
$$h_2(s) = 2 + 3 + 3 + 2 + 4 + 2 + 0 + 2 = 18$$

Heuristische Funktion

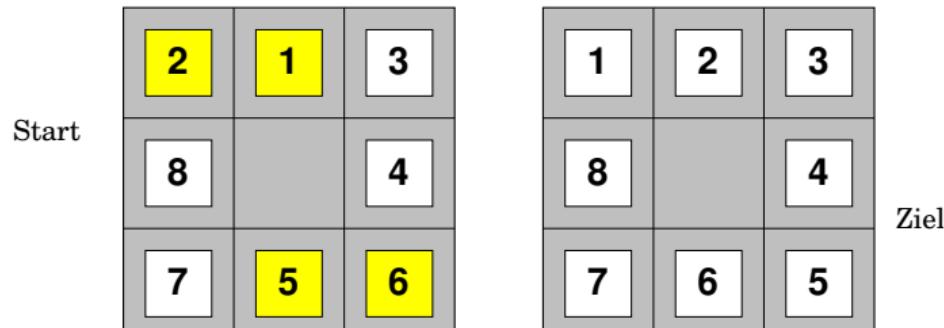


- Die heuristische Funktion h_2 differenziert stärker als h_1 , d.h. h_2 kann Zustände unterscheiden, die von h_1 gleich bewertet werden.
- Eine heuristische Funktion ist um so brauchbarer, je mehr Zustände sie unterschiedlich bewertet.
- Eine heuristische Funktion, die alle Zustände gleich bewertet, ist unbrauchbar.

Heuristische Funktion

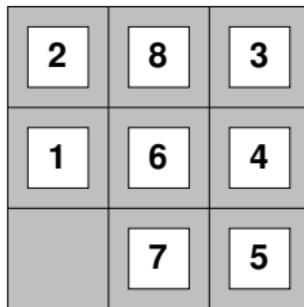
Beide Heuristiken sind zu kritisieren, da sie die Schwierigkeiten eines Spielsteintauschs nicht berücksichtigen:

- Es sind wesentlich mehr als zwei Verschiebungen notwendig, da die Plättchen umeinander herum verschoben werden müssen.
- Man kann eine kleine Zahl wie 2 auf die Heuristik multiplizieren, um dies zu berücksichtigen.

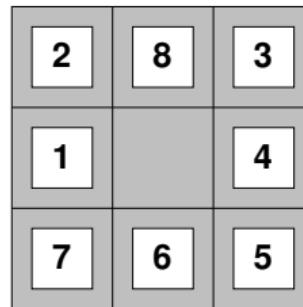


- $h_3(s) = 2 \times \text{Anzahl direkter Spielsteintausch}$

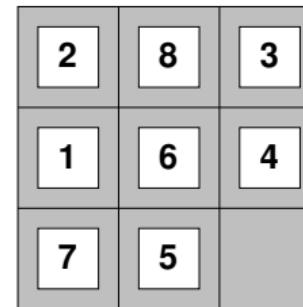
- h_3 versagt, wenn ein Zustand keinen direkten Tausch enthält:



$h_1: 5$ $h_2: 6$ $h_3: 0$



$h_1: 3$ $h_2: 4$ $h_3: 0$



$h_1: 5$ $h_2: 6$ $h_3: 0$

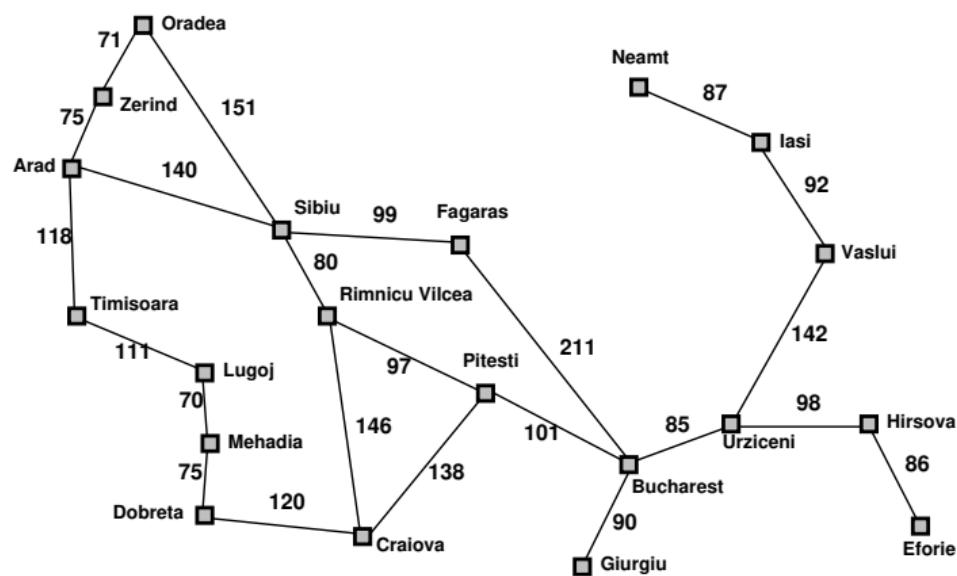
- Heuristik h_4 : Die Summe der Entfernungen plus das Doppelte der Anzahl direkter Tauschkonfigurationen.
- Heuristik: Begrenzte Information über Zustandsbeschreibung einsetzen, um intelligente Auswahl zu treffen.
- Jede obige Heuristik ignoriert wichtigen Informationsanteil.
- Urteilsvermögen und Intuition sind hilfreich, aber Bewertung basiert letztendlich auf tatsächlicher Leistung beim Lösen von Probleminstanzen.

Wir schreiben im Folgenden $h_t(s)$ für den Wert der heuristischen Funktion für Zustand s bei Ziel t .

Bei manchen Problemen wie TSP oder Knapsack ist der Zielzustand nicht bekannt, bei anderen wie Routenplanung ändert sich das Ziel.

- Beim 15-Puzzle gibt es nur ein Ziel, dort schreiben wir $h(s)$ für die heuristische Funktion, der Index t kann entfallen.
- Bei der Routenplanung ist der Index t wichtig, weil in der Regel bei jeder neuen Routenplanung ein anderes Ziel ausgewählt wird. Es könnte auch eine Funktion mit zwei Parametern definiert werden: $h_t(s) = h(s, t)$
- Bei Problemen wie TSP oder Knapsack sind die Zielzustände nicht bekannt, sonst gäbe es kein Problem, was zu lösen wäre. Daher nutzen wir bei solchen Problemen eine Abschätzung zum „theoretischen Optimum“, also bspw. den Wert eines minimalen Spannbaums bei TSP oder den Wert des Bruchteil-Rucksackproblems bei Knapsack. Auch hier kann der Index t entfallen.

Beispiel Routenplanung: Die Straßenentfernung wird durch die Luftlinienentfernung abgeschätzt, hier am Beispiel von Rumänien:



Straight-line distance to Bucharest	
Arad	366
Bucharest	0
Craiova	160
Dobreta	242
Eforie	161
Fagaras	178
Giurgiu	77
Hirsova	151
Iasi	226
Lugoj	244
Mehadia	241
Neamt	234
Oradea	380
Pitesti	98
Rimnicu Vilcea	193
Sibiu	253
Timisoara	329
Urziceni	80
Vaslui	199
Zerind	374

Bei der Bestensuche erfolgt die Expansion eines Knotens auf Basis der heuristischen Funktion:

- Die Heuristik wählt den vielversprechendsten Zustand aus.
- Hierzu werden in der Agenda die Knoten zusammen mit ihrer Bewertung abgelegt.
- Es wird jeweils der Knoten der Agenda expandiert, der die geringste Bewertung aufweist.
- Die Agenda hat also die Form einer Prioritätswarteschlange (priority queue).
- Ansonsten ist die Bestensuche analog zur Tiefen- und Breitensuche.

```
Node * BestSearch(Node *pRoot) { //ggf. Ziel t als Parameter
    PriorityQueue<Node *> agenda;
    agenda.insert(pRoot, h(pRoot)); // ggf. h(pRoot, t)
    HashSet<Node *> closedList;

    while (not agenda.isEmpty()) {
        Node *pCurr = agenda.extractMin();

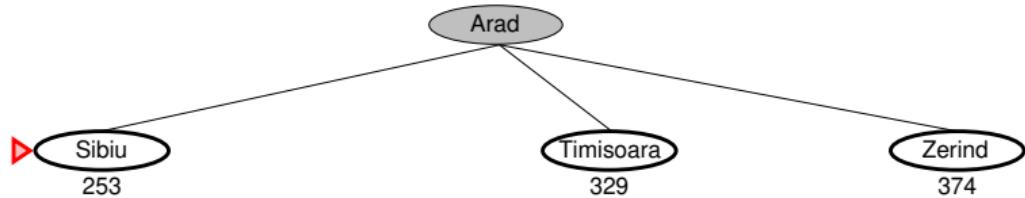
        if (zielknoten(pCurr))
            return pCurr;

        if (not closedList.contains(pCurr)) {
            closedList.insert(pCurr);
            for (Node *n : nachfolger(pCurr))
                agenda.insert(n, h(n)); // ggf. h(n, t)
        }
    }
    return null;
}
```

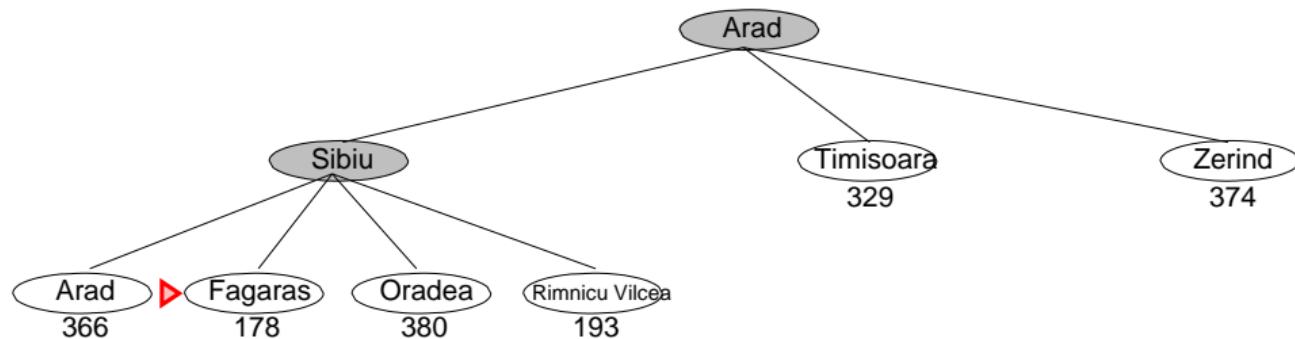
Routenplanung:

► Arad
366

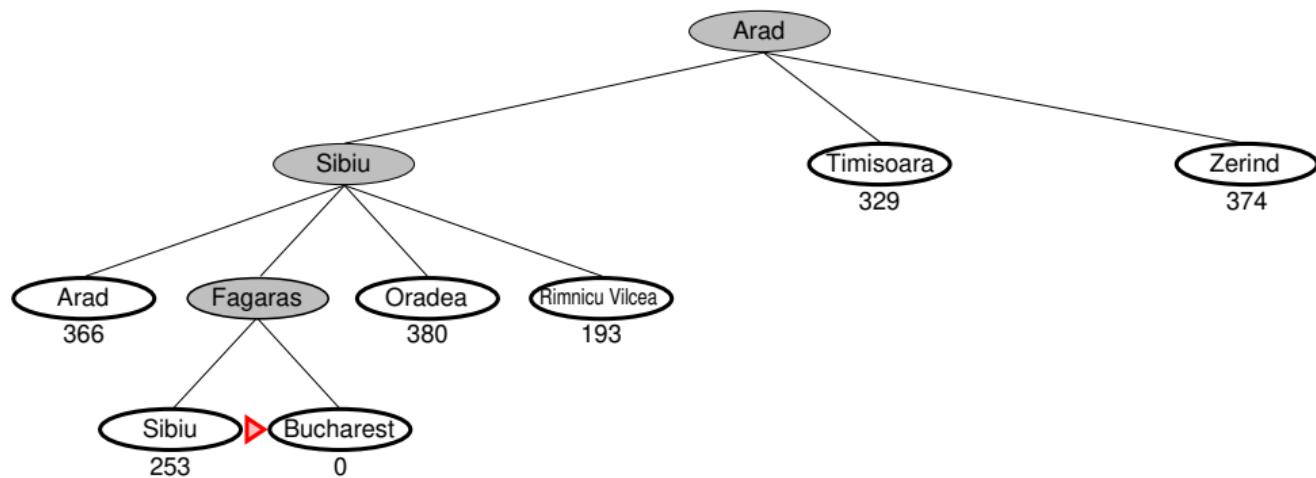
Routenplanung:



Routenplanung:



Routenplanung:



- Die gefundene Lösung ist nicht optimal!
- Bestensuche wählt Route über Sibiu und Fagaras, obwohl die Route über Rimnicu Vilcea und Pitesti kürzer ist.
- Heuristiken können versagen: Eine Heuristik ist nur eine informierte Vermutung, basierend auf Erfahrung und Intuition.

Die Bestensuche ist anfällig für falsche Startknoten!

- Beispiel: Suche Route von Iasi nach Fagaras.
- Zuerst wird Neamt expandiert, weil es näher am Ziel ist als Vaslui, aber die Route führt in eine Sackgasse.
- Die richtige Route führt zunächst über Vaslui, obwohl es weiter vom Ziel entfernt ist als Neamt.

→ Heuristik expandiert unnötige Knoten.

Ohne Erkennung wiederholter Zustände würde die Suche zwischen Iasi und Neamt oszillieren.

Analogie zur Tiefensuche:

- Verfolge nur einen Pfad zum Ziel, um die Speicherkomplexität gering zu halten
- und springe zurück, falls in eine Sackgasse verzweigt wurde.

Gleiche Nachteile wie Tiefensuche:

- Die Bestensuche ist nicht optimal und
- nicht vollständig (kann in unendlichem Pfad hängen bleiben).

Komplexität: Sei b die Verzweigungsrate und m die maximale Tiefe des Baums. Dann ergeben sich folgende Komplexitäten:

- Zeit: $\mathcal{O}(b^m)$
- Platz: $\mathcal{O}(b^m)$

Eine heuristische Funktion h heißt *fair* gdw. es zu jedem $n \geq 0$ nur endlich viele Knoten s gibt mit $h(s) \leq n$.

- Fairness entspricht der Vollständigkeit bei uninformierten Suchverfahren.
- Ist eine heuristische Funktion fair, so wird ein Zielknoten gefunden, falls ein solcher existiert.

Problem:

- Die Bestensuche vernachlässigt die Kosten bei der Anwendung der Operatoren.
- Wird die Güte einer Lösung charakterisiert durch diese Operatorkosten, so findet die Bestensuche i.Allg. keine optimale Lösung.
 - Routenberechnung: Distanz vom Start zum aktuellen Knoten
 - 8-Puzzle: Anzahl bisher durchgeführter Züge

Heuristiken sind fehlbar, daher verfolgt ein Suchalgorithmus evtl. einen Weg, der nicht zu einem Ziel führt.

- Lösung des Problems bei Tiefensuche: Ein Tiefenzähler wurde genutzt, um aussichtslose Wege zu entdecken.
- Diese Idee ist auch bei heuristischer Suche anwendbar.

Bei gleicher heuristischer Bewertung ziehe den Zustand vor, der sich näher an der Wurzel des Graphen befindet.

- Dieser Knoten hat eine größere Wahrscheinlichkeit, auf dem *kürzesten Weg* zum Ziel zu liegen.
- Jedem Zustand wird ein Tiefenzähler zugewiesen, der für jede Ebene um eins hochgezählt wird.
- Bewertungsfunktion f ist die Summe aus zwei Komponenten.
 - $g(n)$: Tatsächliche Länge des Weges vom Start zum Zustand n .
 - $h(n)$: Schätzung der Entfernung von n zu einem Ziel.

Die Komponente $g(n)$ verleiht der Suche eine stärkere Tendenz zur Breitensuche.

- Dies verhindert, dass die Suche von einer fehlerhaften Bewertung in die Irre geführt wird.
- Der Algorithmus verliert sich nicht dauerhaft in einem unendlichen Zweig, falls eine Heuristik kontinuierlich gute Bewertungen abgibt.
- Jeder Zustand muss darauf untersucht werden, ob er schon mal aufgetreten ist, um Schleifen zu verhindern. → Closed-List

Wird ein bereits generierter Zustand n auf einem kürzeren Weg noch einmal erreicht, muss die Bewertung angepasst werden.

- Ist Zustand n in der Open-List enthalten, dann muss der neue Wert $g(n) + h(n)$ in der Priority-Queue gesetzt werden.
- Wurde Zustand n bereits abgearbeitet und in die Closed-List eingefügt, dann muss n der Closed-List entnommen und mit neuem Wert wieder in die Agenda aufgenommen werden.

A^* -Algorithmus

```
// global data structures
PriorityQueue<Node *> openList;
HashMap<Node *, double> g;
HashSet<Node *> closedList;

Node * AStarSearch(Node *pRoot) {
    g[pRoot] := 0;
    openList.insert(pRoot, h(pRoot));
    while (not openList.isEmpty()) {
        Node *pCurr = openList.extractMin();
        if (zielknoten(pCurr))
            return pCurr;

        expandNode(pCurr);
        closedList.insert(pCurr);
    }
    return null;
}
```

A[∗]-Algorithmus

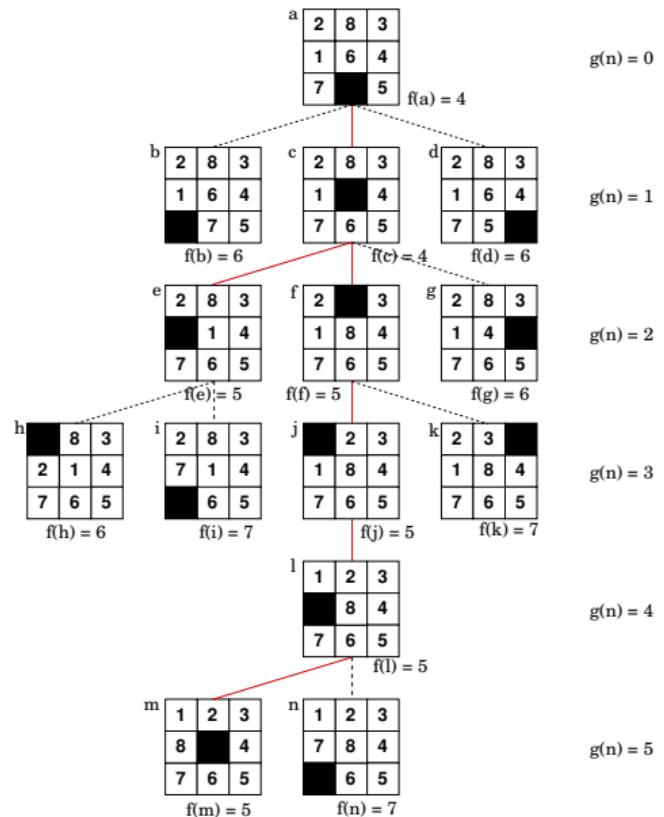
```
void expandNode(Node *pCurr) {
    for (Node *n : nachfolger(pCurr)) {
        double c := g[pCurr] + cost(pCurr, n);
        if (openList.contains(n)) {
            if (c < g[n]) // shorter path found
                updateOpenList(n, c);
            else ; // do nothing
        } else {
            // n not contained in open list
            if (closedList.contains(n)) {
                if (c < g[n]) // shorter path found
                    updateClosedList(n, c);
                else ; // do nothing
            } else
                // first visit of n
                insertOpenList(n, c);
        }
    }
}
```

```
void updateOpenList(Node *n, double c) {
    g[n] := c;
    openList.decreaseKey(n, c + h(n));
}

void updateClosedList(Node *n, double c) {
    g[n] := c;
    openList.insert(n, c + h(n));
    closedList.erase(n);
}

void insertOpenList(Node *n, double c) {
    g[n] := c;
    openList.insert(n, c + h(n));
}
```

Schiebepuzzle



Sei $p = (s_0, s_1, \dots, s_r)$ eine Folge von Zuständen und s_{i+1} sei durch Anwendung eines Zustandsübergangsoperators auf s_i erreichbar.

Wenn beim Übergang von s_i nach s_{i+1} Kosten in Höhe von $k(s_i, s_{i+1})$ anfallen, dann seien die Kosten $k(p)$ der Zustandsfolge definiert durch:

$$k(p) := \sum_{i=0}^{r-1} k(s_i, s_{i+1})$$

Für einen Zustand s bezeichne

- $g^*(s)$ die minimalen Kosten vom Start nach s :

$$g^*(s) := \inf\{k(p) \mid p \text{ ist Weg vom Startzustand nach } s\}$$

- $h^*(s)$ die minimalen Kosten von s zum Ziel:

$$h^*(s) := \inf\{k(p) \mid p \text{ ist Weg von } s \text{ zu einem Zielzustand}\}$$

Betrachtet man also einen Zustand s , der auf einem Suchpfad vom Startzustand zum Zielzustand liegt, dann hat der kürzeste Weg, der über den Zustand s läuft, die Länge $g^*(s) + h^*(s)$:

$$\text{Start} \xrightarrow{g^*(s)} s \xrightarrow{h^*(s)} \text{Ziel}$$

Der Wert $g^*(n)$ ist eine untere Schranke für den Wert $g[n]$ aus dem A^* -Algorithmus, es gilt also $g[n] \geq g^*(n)$. Da in der Regel ein Knoten auf verschiedenen Wegen erreicht werden kann, gilt die Gleichheit $g[n] = g^*(n)$ oft erst nach mehreren Runden.

Problem: Finde eine Zustandsfolge p' vom Startzustand s_0 in einen Zielzustand z , die minimale Kosten aufweist, d.h.:

$$k(p') = h^*(s_0) \text{ bzw.}$$

$$k(p') = \inf\{g^*(z) \mid z \text{ ist Zielzustand}\}$$

Der Wert $g^*(z)$ ist gesucht, aber auch die Funktion h^* ist wichtig: Wir benötigen diese Funktion, um zulässige Schätzer zu definieren.

Eine heuristische Funktion h heißt *zulässiger Schätzer* bzw. *zulässig*, falls $h(s) \leq h^*(s)$ für alle Zustände s des Zustandsraums gilt. Mit anderen Worten: Bei den hier betrachteten Minimierungsproblemen darf ein zulässiger Schätzer die echten Kosten nicht überschätzen!

Zulässige Schätzer sind:

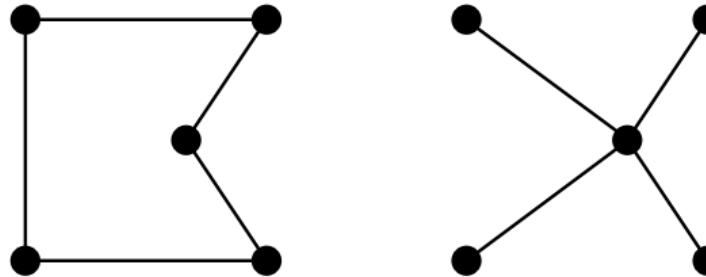
- Die heuristischen Funktionen für das Schiebepuzzle.
- Die Luftlinienentfernung beim Routenproblem.

Bei kombinatorischen Optimierungsproblemen werden als zulässige Schätzer häufig effizient lösbarer Relaxationen des Problems verwendet: Vernachlässigte Nebenbedingungen, so dass sich ein einfacher zu lösendes Problem ergibt.

Beispiel: Minimaler Spannbaum als Relaxation für die Berechnung eines minimalen Hamiltonschen Weges.

Well-known example: Travelling salesperson problem (TSP).

Find the shortest tour visiting all cities exactly once.



Minimum spanning tree (MST) can be computed in $\mathcal{O}(n^2)$ and is a lower bound on the shortest (open) tour.

Frage: Was hat MST mit TSP zu tun?

Antwort: Lässt man auf einer Rundreise eine Kante weg, erhält man einen Spannbaum. Die Kosten eines MST sind also höchstens so groß wie die Kosten einer minimalen Rundreise.

Relaxationen entstehen oft durch Weglassen oder Lockern von Bedingungen.

Beispiel: 8-Puzzle

- Ein Stein kann direkt überall plaziert werden, auch auf bereits belegten Feldern.
→ h_1 ergibt exakte Anzahl Schritte der optimalen Lösung.
- Ein Stein kann in alle Richtungen bewegt werden, auch auf ein schon belegtes Feld.
→ h_2 ergibt exakte Anzahl Schritte der optimalen Lösung.

Achtung: Die Kosten einer optimalen Lösung eines relaxierten Problems sind *zulässige Schätzer* des originalen Problems!

Eine optimale Lösung des Originalproblems ist auch eine Lösung des relaxierten Problems, und ist mindestens so teuer wie die optimale Lösung des relaxierten Problems.

A^* -Algorithmus (allgemein)

- Durch eine Verringerung von $g(s)$ für einen Zustand s kann auch eine Verringerung von $f(s)$ auftreten.
- Dies kann auch für schon expandierte Knoten der Fall sein.
- Sind Bewertungen von bereits expandierten Knoten anzupassen, *werden diese aus der Closed-List entfernt und wieder in die Agenda aufgenommen*.
- Dadurch können sie später erneut betrachtet werden.

Monotone Schätzer

- Zulässiger Schätzer, der die Dreiecksungleichung erfüllt, d.h. für alle Zustände s und alle Nachfolger s' von s gilt: $h(s) \leq k(s, s') + h(s')$
- *Bei Einsatz von monotonen Schätzern im A^* -Algorithmus werden expandierte Knoten nie wieder betrachtet.*

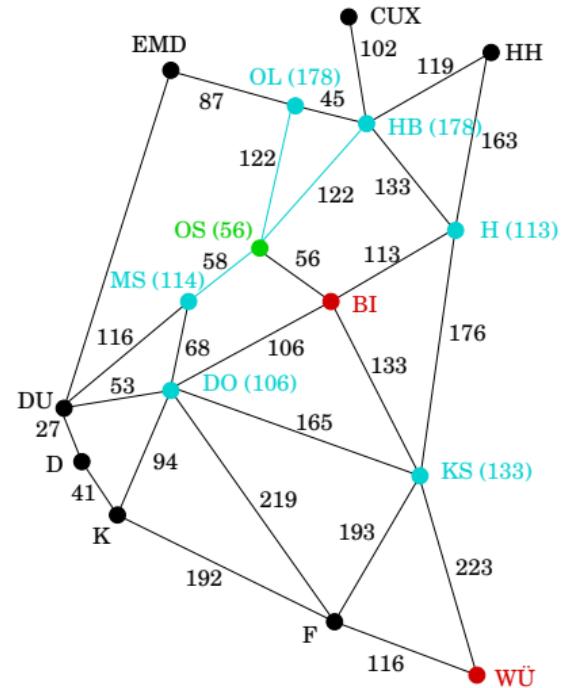
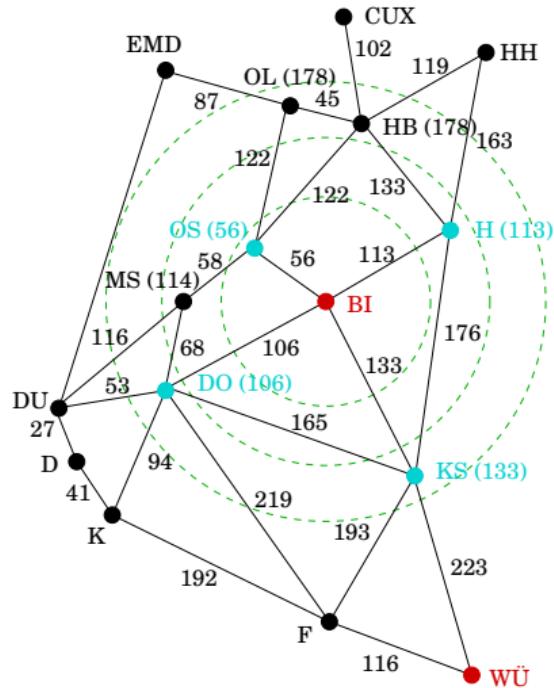
→ Die Closed-List kann entfallen.

Vereinfachung des A^* -Algorithmus für monotone Heuristik:

```
Node * AStarSearch(Node *pRoot) {
    HashMap<Node *, double> g;
    PriorityQueue<Node *> agenda;
    g[pRoot] := 0;
    agenda.insert(pRoot, h(pRoot));
    while (not agenda.isEmpty()) {
        Node *pCurr = agenda.extractMin();
        if (zielknoten(pCurr))
            return pCurr;

        for (Node *n : nachfolger(pCurr)) {
            g[n] := g[pCurr] + cost(pCurr, n);
            agenda.insert(n, g[n] + h(n));
        }
    }
    return null;
}
```

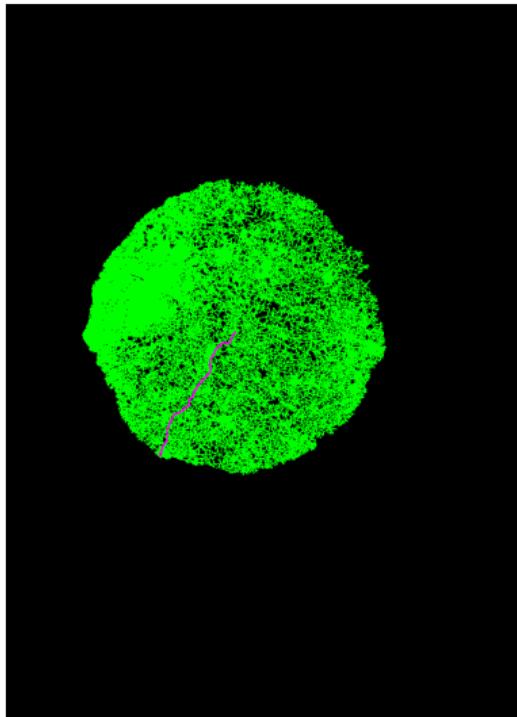
Dijkstra: Suche von Bielefeld nach Würzburg



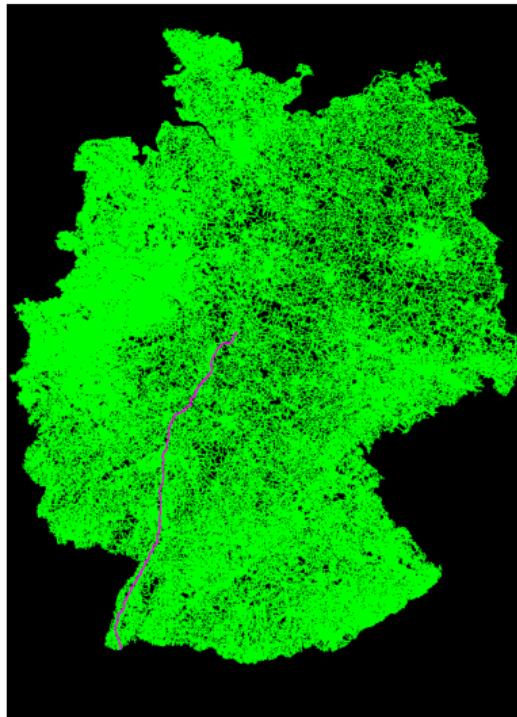
Die Suche breitet sich in alle Richtungen gleichmäßig aus, also kreisförmig um den Startknoten, bis das Ziel gefunden wird.

Dijkstra: kreisförmige Ausbreitung der Suche

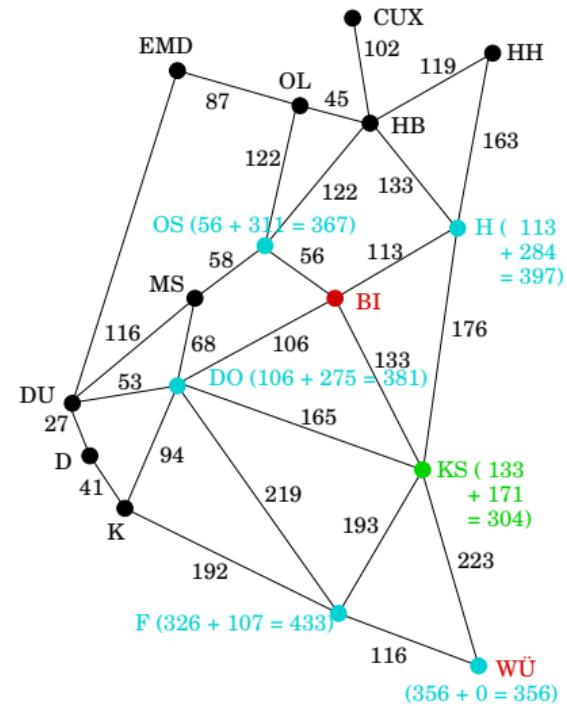
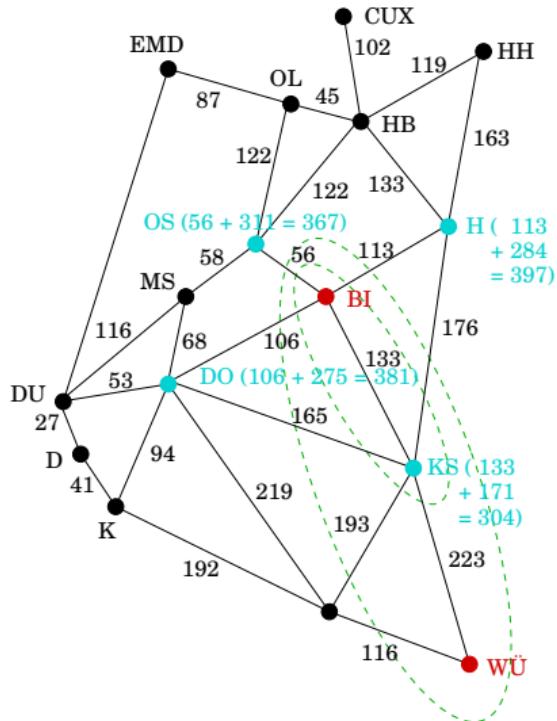
von Göttingen nach Frankfurt



von Göttingen nach Freiburg i.B.



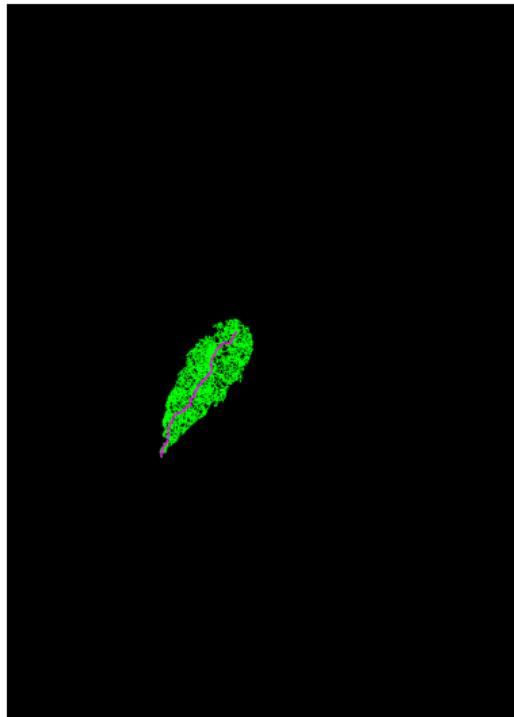
A[∗]: Suche Weg von Bielefeld nach Würzburg



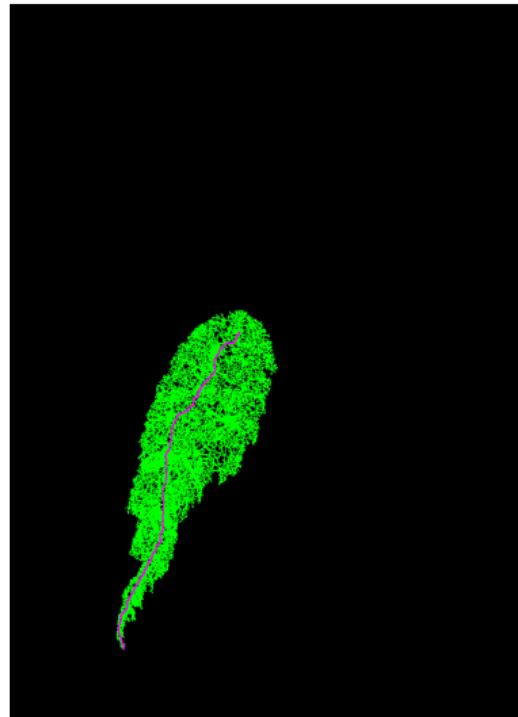
Durch die Schätzfunktion findet die Suche „zielgerichtet“ statt, nicht in zentralen Kreisen, sondern in Konturen.

A^* : zielgerichtete Ausbreitung der Suche

von Göttingen nach Frankfurt

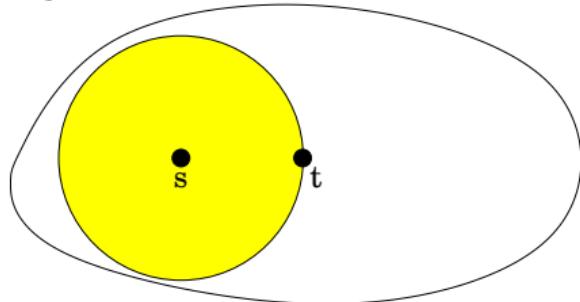


von Göttingen nach Freiburg i.B.

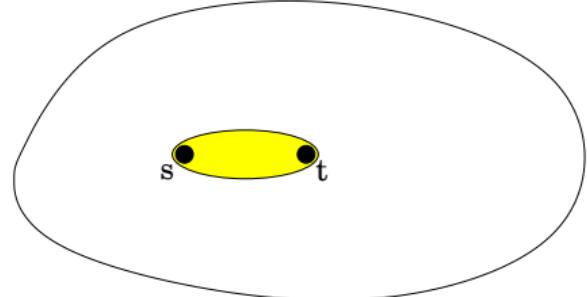


Routenplanung

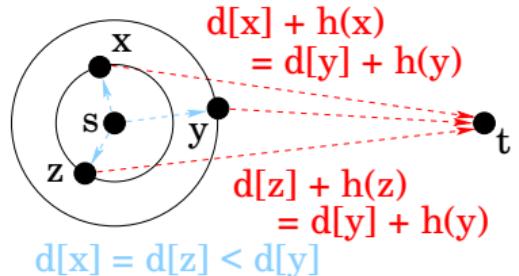
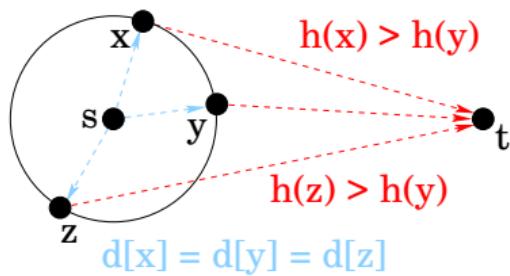
Dijkstra:



A^* :



Entstehung der Kontur durch Einsatz der Luftliniendistanz:



Aus der Vorlesung ALD (Bachelor Informatik) wissen wir, dass der Algorithmus von Dijkstra korrekt ist, solange keine Kante e mit negativer Bewertung $cost(e)$ im Graphen enthalten ist. Die Agenda bezeichnen wir mit Q , die Closed-List mit S .

```
d[s] := 0
Q.add(s, 0)
while not Q.isEmpty() do
    u := Q.extractMin()
    if u ist Ziel t then return d[u]
    S.insert(u)
    for each e = (u, v) ∈ E and not S.contains(v) do
        if not Q.contains(v) then
            d[v] := d[u] + cost(e)
            Q.insert(v, d[v])
        else if d[v] > d[u] + cost(e) then
            d[v] := d[u] + cost(e)
            Q.decreaseKey(v, d[v])
```

Sei t das Ziel und sei h_t ein monotoner Schätzer, so dass $h_t(u) \leq \text{cost}(u, v) + h_t(v)$ für alle $(u, v) \in E$ gilt.

```
d[s] := 0
Q.add(s, ht(s))
while not Q.isEmpty() do
    u := Q.extractMin()
    if u ist Ziel t then return d[u]
    S.insert(u)
    for each e = (u, v) ∈ E and not S.contains(v) do
        if not Q.contains(v) then
            d[v] := d[u] + cost(e)
            Q.insert(v, d[v] + ht(v))
        else if d[v] > d[u] + cost(e) then
            d[v] := d[u] + cost(e)
            Q.decreaseKey(v, d[v] + ht(v))
```

Abarbeitung der Knoten:

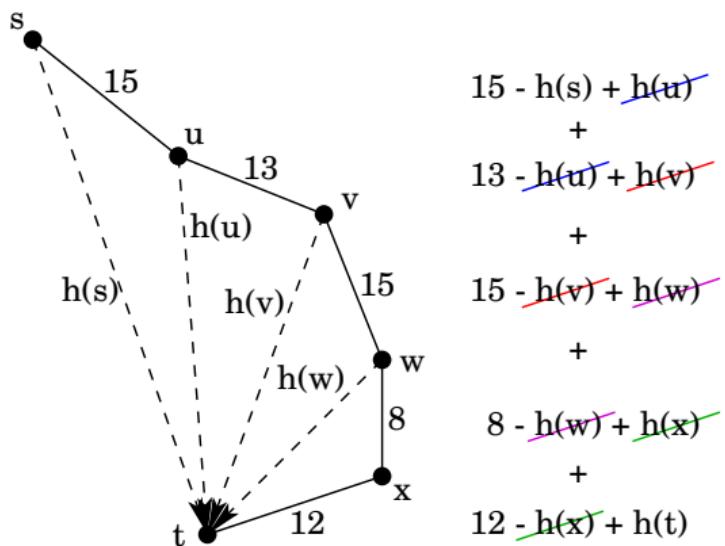
- Dijkstra: Knoten u vor Knoten v , wenn $d[u] < d[v]$
- A^* : Knoten u vor Knoten v , wenn $d[u] + h(u) < d[v] + h(v)$

Wir definieren für $(u, v) \in E$

$$cost_h(u, v) := cost(u, v) - h(u) + h(v)$$

und ersetzen in G die alte durch die neue Kostenfunktion und erhalten so G_h .

Die Länge aller Pfade vom Start s zum Ziel t ändert sich um den selben Wert $h(t) - h(s)$, daher bleiben alle kürzesten Wege erhalten: $d_h(s, u) = d(s, u) - h(s) + h(u)$



Korrektheit A^* -Algorithmus

Sei $P = (v_1, v_2, \dots, v_k)$ ein Weg in G von $s = v_1$ nach $t = v_k$. Dann gilt:

$$\begin{aligned} \text{cost}_h(P) &= \sum_{i=1}^{k-1} \text{cost}_h(v_i, v_{i+1}) = \sum_{i=1}^{k-1} \left(\text{cost}(v_i, v_{i+1}) - h(v_i) + h(v_{i+1}) \right) \\ &= \left(\sum_{i=1}^{k-1} \text{cost}(v_i, v_{i+1}) \right) - h(v_1) + h(v_k) = \text{cost}(P) - h(s) + h(t) \end{aligned}$$

Die Reihenfolge der besuchten Knoten von Dijkstra im neuen Graphen G_h entspricht also der von A^* in G , da $h(s)$ für alle Knoten gleich ist.

A^* ist also korrekt, wenn $\text{cost}_h(u, v) \geq 0$ für alle $(u, v) \in E$ ist.

- Dies folgt unmittelbar aus der Dreiecksungleichung $h(u) \leq \text{cost}(u, v) + h(v)$ des monotonen Schätzers h ,
- denn $h(u) \leq \text{cost}(u, v) + h(v) \iff 0 \leq \text{cost}(u, v) - h(u) + h(v) = \text{cost}_h(u, v)$.

Übung 17. Betrachten Sie das 0/1-Rucksackproblem.

- Gegeben: Eine Menge von n Objekten und ein maximales Gesamtgewicht W .
- Jedes Objekt i hat ein Gewicht w_i und liefert einen Profit p_i .

Bestimme eine Teilmenge F der Objekte, so dass folgendes gilt:

- Der Gesamtprofit $\sum_{i \in F} p_i$ von F ist maximal
- unter der Nebenbedingung $\sum_{i \in F} w_i \leq W$.

Zentrale Fragen:

- Formulierung des 0/1-Rucksackproblems als Suchproblem?
- Was muss ein A^* -Algorithmus für das 0/1-Rucksackproblem berücksichtigen?
- Abschätzung des noch erzielbaren Nutzens?

Übung 18. Implementieren Sie den A^* -Algorithmus zum Lösen des m -Puzzles mit $m = n^2 - 1$ und vergleichen Sie die Laufzeiten für $n = 3, 4, 5, 6$.

- Wie effektiv ist die heuristische Funktion h_2 im Vergleich zu h_1 ?
- Ist die heuristische Funktion h_2 auch für größere Puzzle effektiv?
- Recherchieren Sie im Internet, wie die Heuristik h_2 erweitert werden kann, um genauere Abschätzungen zu liefern.

Vergleichen Sie die Laufzeiten des obigen Programms mit den Laufzeiten des Integer-Programms, das wir mittels GLPK implementiert hatten.

Je genauer die Heuristik ist, desto weniger Knoten werden untersucht.

Begrenzender Faktor beim A^* -Algorithmus ist der Speicherplatz, da alle bekannten Knoten im Speicher gehalten werden.

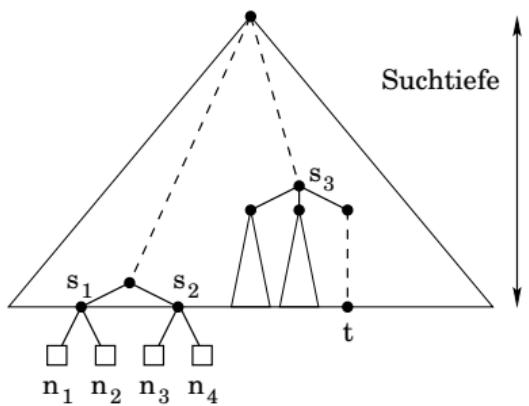
- A^* -Algorithmus ist nicht geeignet, falls keine monotone Heuristik bekannt ist.
- iterative deepening: Suchtiefe begrenzen und schrittweise vergrößern, bis eine Lösung gefunden wird.

IDA * : Iterative Deepening A^*

- Die erste Grenze für die Suchtiefe ist der Wert der Heuristik für den Startknoten. Da die Heuristik zulässig ist, gibt es keinen kürzeren Weg vom Start zum Ziel.
- Die rekursive Suche innerhalb der Schleife liefert entweder eine Lösung oder das Minimum der per Heuristik bestimmten Weglänge für alle Knoten, die als erste Knoten hinter der Grenze gefunden wurden. Dieses Minimum wird für den nächsten Schleifendurchlauf als Grenze für die Suchtiefe verwendet.

Iterative Deepening A*

IDA* entspricht einer tiefenbeschränkten, rekursiven Tiefensuche, aber der Abbruch erfolgt bei einem Knoten s schon dann, wenn $f(s) = g(s) + h(s)$ größer als die vorgegebene Suchtiefe ist.



- s_1 : Rückgabe $\min\{f(n_1), f(n_2)\}$
- s_2 : Rückgabe $\min\{f(n_3), f(n_4)\}$
- s_3 : Rückgabe Zielknoten t

Die Suchtiefe wird nicht bei jedem Durchlauf um eins vergrößert, sondern um $\min_j\{f(n_j)\}$, falls die Einheit der Tiefe nicht die Anzahl der Kanten ist. Bei der Routenplanung sind bspw. nicht die Anzahl der Kanten, sondern die Entfernung in km die Einheit der zu optimierenden Funktion.

Würde jeweils um einen festen Wert wie z.B. 1 km erhöht, dann wird ggf. keine optimale Lösung gefunden, oder es würden in mehreren Runden immer wieder dieselben Knoten untersucht ohne Fortschritt der Lösungsfindung.

Iterative Deepening A*

Die rekursive Funktion `search(node, g, limit)` wird auf der nächsten Seite beschrieben. Dabei bezeichnet `node` den Startknoten der Suche, `g` die bisherigen Kosten, um den Startknoten zu erreichen, und `limit` die maximale Suchtiefe.

```
Node * idaStar(Node *root) {
    int limit := h(root);

    while (true) {
        pair<Node *, int> p := search(root, 0, limit);
        if (p.first != null)
            return p.first;
        limit := p.second;
    }
    return null;
}
```

Iterative Deepening A*

```
pair<Node *, int> search(Node *node, int g, int limit) {
    int f := g + h(node);
    if (f > limit)
        return pair<Node *, int>(null, f);

    if (zielknoten(node))
        return pair<Node *, int>(node, 0);

    int min := Integer.MAX_VALUE;
    for (Node *n : nachfolger(node)) {
        pair<Node *, int> p := search(n, g + cost(node, n), limit);
        if (p.first != null)
            return p;
        if (p.second < min)
            min := p.second;
    }
    return pair<Node *, int>(null, min);
}
```

Manhattan distance enhanced by *linear conflicts*: Historically, the linear-conflict heuristic was the first significant improvement over Manhattan distance⁽⁶²⁾. It applies to tiles in their goal row or column, but reversed relative to each other. For example, assume the top row of a given state contains the tiles (2 1) in that order, but in the goal state they appear in the order (1 2). To reverse them, one of the tiles must move out of the top row, to allow the other tile to pass by, and then move back into the top row. Since these two moves are not counted in the Manhattan distance of either tile, two moves can be added to the sum of the Manhattan distances of these two tiles without violating admissibility.

Übung 19. Implementieren Sie den *IDA*^{*}-Algorithmus am Beispiel des 15-Puzzles sowie die Linear-Conflicts-Heuristik. Vergleichen Sie die Laufzeiten mit Ihrer Implementierung des *A*^{*}-Algorithmus.

⁽⁶²⁾O. Hansson, A. Mayer, M. Yung, Criticizing solutions to relaxed models yields powerful admissible heuristics, *Information Science* 63 (3) (1992) 207–227.

15-Puzzle⁽⁶³⁾: The efficiency of A^* searching depends on the quality of the lower bound estimates of the solution cost. The A^* search algorithm is of fundamental importance in artificial intelligence. Improvements to the search efficiency can take the range from general algorithm enhancements (application independent) to problem-specific heuristics (application dependent):

- General search space properties. Many search domains can be represented as directed graphs rather than as trees. The removal of duplicate nodes from the search can result in potentially large savings (Marsland and Reinefeld 1994; Taylor and Korf 1993).
- Solution databases. In many problems, the states near to the goal nodes can be precomputed by a backwards search. In two-player games, such as chess and checkers, the backwards searches are saved in *endgame databases* and are used to stop the search early, improving search efficiency and accuracy (Schaeffer et al. 1992).

⁽⁶³⁾ Joseph C. Culberson, Jonathan Schaeffer: Pattern Databases. Computational Intelligence 14(3): 318-334 (1998)

15-puzzle⁽⁶⁴⁾: On larger problems, *IDA** with Manhattan distance takes too long, and more accurate heuristic functions are needed. While Manhattan distance sums the cost of solving each tile independently, we consider the costs of solving several tiles simultaneously, taking into account the interactions between them.

The reason the problem is difficult, and why Manhattan distance is only a lower bound on actual solution cost, is that the tiles get in each other's way. By taking into account some of these interactions, we can compute more accurate admissible heuristic functions.

Consider a subset X of the Fifteen Puzzle tiles. For a given state, the minimum number of moves needed to get the tiles of X to their goal positions, including required moves of other tiles, is a lower bound on the number of moves needed to solve the entire puzzle.

⁽⁶⁴⁾Richard E. Korf, Ariel Felner: Disjoint pattern database heuristics. Artificial Intelligence 134(1-2): 9-22 (2002)

This number depends on the current positions of the tiles of X and the blank, but is independent of the positions of the other tiles. Thus, we can precompute all these values, store them in memory, and look them up as they are needed during the search.

We can compute this entire table with a single breadth-first search backward from the goal state. The unlabelled tiles are all equivalent, and a state is uniquely determined by the positions of the tiles in X and the blank. As each configuration of these tiles is encountered for the first time, the number of moves made to reach it is stored in the corresponding entry of the table, until all entries are filled. Note that this table is only computed once for a given goal state, and its cost is amortized over the solution of multiple problem instances with the same goal state.

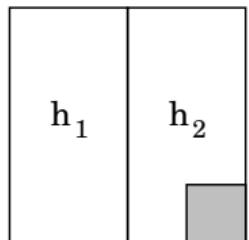
1	2	3	4
5			
9			
13			

goal state

The main limitation of non-additive pattern databases is that they can't solve larger problems. *With multiple databases, the best way to combine them admissibly is to take the maximum of their values*, even if the sets of tiles are disjoint. The reason is that *non-additive pattern database values include all moves needed to solve the pattern tiles, including moves of other tiles*.

Instead of taking the maximum of different pattern database values, we would like to be able to sum their values, to get a more accurate heuristic, without violating admissibility. This is the main idea of disjoint pattern databases.

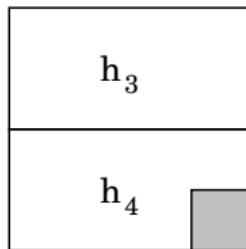
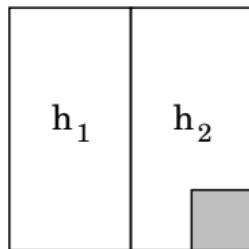
To construct a disjoint pattern database for the sliding-tile puzzles, we partition the tiles into disjoint groups, such that no tile belongs to more than one group. We then precompute tables of the *minimum number of moves of the tiles in each group that are required to get those tiles to their goal positions*. We call the set of such tables, one per group of tiles, a disjoint pattern database, or a disjoint database for short.



Then, given a particular state in the search, for each group of tiles, we use the positions of those tiles to compute an index into the corresponding table, retrieve the number of moves required to solve the tiles in that group, and then add together the values for each group, to compute an overall heuristic for the given state. This value will be at least as large as the Manhattan distance, and usually larger, since it accounts for interactions between tiles in the same group.

The key difference between disjoint databases and the non-additive databases described above is that *the non-additive databases include all moves required to solve the pattern tiles, including moves of tiles not in the pattern set*. As a result, given two such databases, even if there is no overlap among their tiles, we can only take the maximum of the two values as an admissible heuristic, because moves counted in one database may move tiles in the other database, and hence these moves would be counted twice. *In a disjoint database, we only count moves of the tiles in the group.*

A second difference between these two types of databases is that our disjoint databases *don't consider the blank position*, decreasing their size. A disjoint database contains the minimum number of moves needed to solve a group of tiles, for all possible blank positions. In neither case is the blank position part of the index to the database.



Die resultierende Heuristik h für die disjoint-database kann noch verbessert werden:

$$h := \max\{h_1(s) + h_2(s), h_3(s) + h_4(s)\}$$

Übung 20. Erweitern Sie Ihre Implementierung des *IDA** um eine Pattern Database. Vergleichen Sie die Laufzeiten mit Ihrer früheren Implementierung für verschiedene Puzzle-Größen. Wie viel Speicherplatz benötigen die Disjoint-Pattern-Databases?

Die Anzahl der verschiedenen Zustände beim m -Puzzle, $m = n^2 - 1$, mit Pattern bestehend aus k Plättchen ist $n^2!/(n^2-k)!$, denn:

- Für das erste Plättchen stehen n^2 viele Positionen zur Auswahl.
- Für das zweite Plättchen stehen noch $n^2 - 1$ viele Positionen zur Auswahl.
- Für das dritte Plättchen stehen noch $n^2 - 2$ viele Positionen zur Auswahl usw..

Im obigen Beispiel einer nicht-additiven Pattern-Database erhalten wir:

$$16!/(16-8)! = 16!/8! = 16 \cdot 15 \cdot 14 \cdot 13 \cdot 12 \cdot 11 \cdot 10 \cdot 9 = 518.918.400$$

Für eine additive (5, 5, 5)-Pattern-Database erhalten wir

$$3 \cdot 16!/(16-5)! = 3 \cdot 524.160 = 1.572.480$$

viele verschiedene Pattern. Um zu jedem der 16 Plättchen die Position zu speichern, benötigen wir etwa $16 \cdot 4 = 64$ Bit oder 8 Byte. Im ersten Fall also etwa 3,9 GB, im zweiten Fall etwa 12 MB.

1 Übersicht

- Informierte Suchverfahren

● Lokale Suche

- Spiele

2 Geschichte und Anwendungen

3 Wissensrepräsentation

4 Zustandsraumsuche

- Uninformierte Suche

5 Aussagenlogik

6 Prädikatenlogik

7 Prolog

Bei vielen Problemen ist nicht der Lösungsweg interessant, stattdessen ist der Zielzustand die eigentliche Lösung.

- 8-Damen-Problem: Nur die Positionen der Damen sind wichtig, nicht in welcher Reihenfolge die Damen platziert wurden.
- Entwurf Integrierter Schaltungen: Nur die letztendliche Platzierung der Bauteile und die Verdrahtung ist wichtig, nicht der Weg, wie das Ziel erreicht wurde.
- Problem des Handlungsreisenden: Nur die Tour ist wichtig.
- Stunden-/Fahrplan Erstellung: Nur der Plan ist wichtig.

Trotz Einsatz von Heuristiken ist die Laufzeit der bisher betrachteten Suchalgorithmen oft noch zu schlecht für einen praktischen Einsatz.

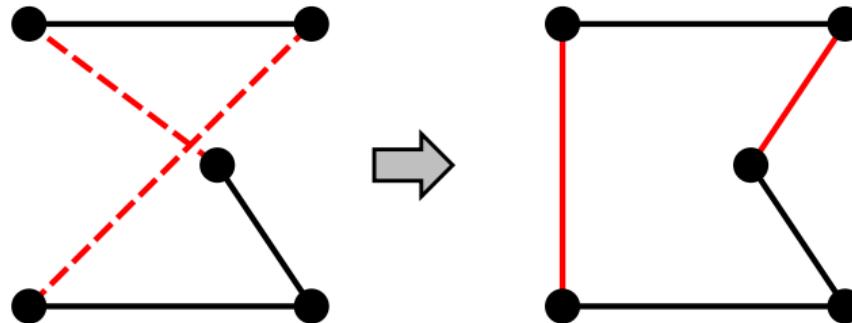
Lokale Suchalgorithmen

- arbeiten mit nur einem einzigen aktuellen Zustand anstelle von mehreren Pfaden.
- versuchen iterativ den aktuellen Zustand zu verbessern.
- besuchen in der Regel nur benachbarte Zustände. Im Gegensatz zu Breiten-, Tiefen- oder Bestensuche, wo die Suche mit dem nächsten Zustand der Agenda fortgesetzt wird.
- speichern die Pfade zur Problemlösung nicht ab.

Vorteile:

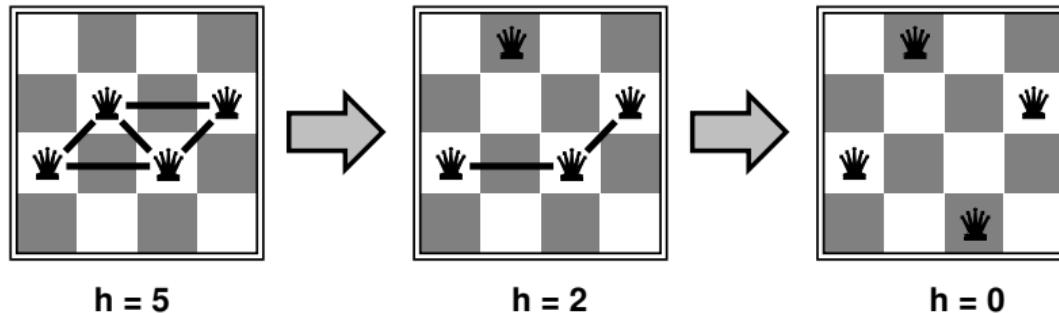
- Sehr geringer Speicherverbrauch.
- Oft werden vernünftige Lösungen in riesigen Suchräumen gefunden.

traveling salesperson problem TSP: start with any complete tour, perform pairwise exchanges



variants of this approach get within 1% of optimal very quickly with thousands of cities

n -queens problem: move a queen to reduce number of conflicts



almost always solves n -queens problems almost instantaneously for very large n , e.g., $n = 1$ million

number of pairs of queens that are attacking each other, either directly or indirectly

18	12	14	13	13	12	14	14
14	16	13	15	12	14	12	16
14	12	18	13	15	12	14	14
15	14	14	14	13	16	13	16
14	14	17	15	14	14	16	16
17	14	16	18	15	14	15	14
18	14	15	15	15	14	14	16
14	14	13	17	12	14	12	18

choose randomly among the set of best successors, if there is more than one

Hill Climbing Search

sometimes called *greedy local search*, because it grabs a good neighbor state without thinking ahead about where to go next

```
function HILL-CLIMBING(problem) : a state that is a local maximum
  inputs: problem, a problem
  local variables: current, a state
                  neighbor, a state

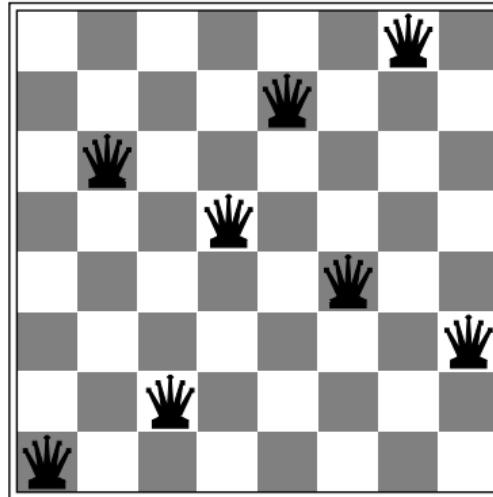
  current  $\leftarrow$  INITIAL-STATE(problem)
  neighbor  $\leftarrow$  a highest-valued successor of current
  while VALUE(neighbor)  $\leq$  VALUE(current) do
    current  $\leftarrow$  neighbor
    neighbor  $\leftarrow$  a highest-valued successor of current
  return current
```

steepest ascent version

“it’s like climbing Everest in thick fog with amnesia”

Hill Climbing Search

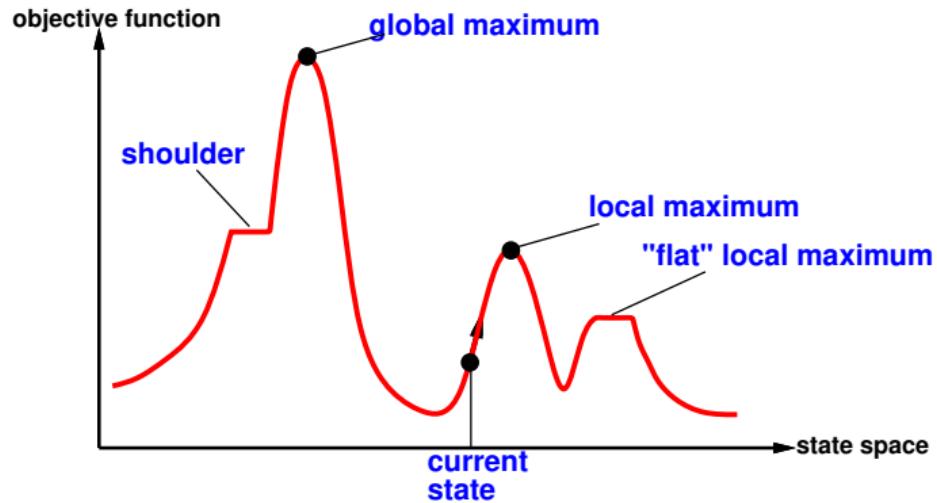
search may be lost in local minimum



each move of a queen would increase the number of conflicts

Hill Climbing Search

useful to consider state space landscape



NP-complete problems typically have an exponential number of local maxima to get stuck on

- *random sideways moves*
 - ☺ escape from shoulders → comes at a cost of higher running time
 - ☺ loop on flat maxima → put a limit on the number of consecutive sideways moves allowed
- *stochastic* choose at random from among the uphill moves
 - ☺ in some landscapes it finds better solutions than steepest ascent
 - ☺ usually converges more slowly
- *first-choice* implements stochastic hill climbing by generating successors randomly until one is generated that is better than the current state
 - good strategy when a state has many of successors
- *random-restart* a reasonably good local maximum can often be found after a small number of restarts
 - overcomes local maxima — trivially complete

Idea: keep k states instead of 1; choose top k of all their successors

- Not the same as k searches run in parallel! Searches that find good states recruit other searches to join them.
- useful information is passed among the k parallel search threads
- Problem: quite often, all k states end up on same local hill

Idea: choose k successors randomly, biased towards good ones

→ stochastic beam search

- observe the close analogy to natural selection

Idee der Tabu-Suche:

- Um lokale Optima verlassen zu können, wird in jedem Schritt die beste erlaubte Nachbarlösung gewählt, auch wenn diese schlechter ist als die aktuelle. → Best-Improvement-Methode
- Nutze eine Gedächtnisstruktur, um die Suche zu steuern.

Um Zyklen beim Traversieren des Suchraums zu vermeiden, werden bereits besuchte Knoten in einer Liste gespeichert.

- Die in der Liste enthaltenen Knoten dürfen in den nächsten Schritten nicht ausgewählt werden.
- Verbiete den Knoten so lange, bis das Wiedererreichen dieser Lösung unwahrscheinlich ist. → Kurzzeitgedächtnis
- Probleme, die experimentell gelöst werden müssen:
 - Wie groß soll die Liste sein?
 - Nach wie vielen Schritten soll ein Eintrag entfernt werden?

Großer Speicherbedarf, wenn ganze Knoten in der Tabu-Liste gespeichert werden.
Daher werden oft nur Attribute verboten:

- Traveling Salesperson: verbiete den Tausch zweier Städte
- Färbung von Graphen: verbiete Farbzuweisung i an Knoten k

Ein Langzeitgedächtnis kann das Verfahren weiter verbessern:

- Mit der Information, wie oft Lösungen untersucht wurden, kann die Suche so gesteuert werden, das bisher wenig betrachtete Bereiche des Lösungsraums untersucht werden.
- Problem: Speicherbedarf wird noch größer.

Simulated Annealing Search

Idea: escape local maxima by allowing some “bad” moves but gradually decrease their size and frequency

- devised by Metropolis et al., 1953, for physical process modelling
- widely used in VLSI layout, airline scheduling, etc.

Simulated Annealing Search

```
function SIMULATED-ANNEALING(problem, schedule) : a solution state
  inputs: problem, a problem
          schedule, a mapping from time to “temperature”
  local variables: current, a state
                    next, a state
                    T, a “temperature” controlling probability of downward steps

  current  $\leftarrow$  INITIAL-STATE(problem)
  for t  $\leftarrow$  1 to  $\infty$  do
    T  $\leftarrow$  schedule[t]
    if T = 0 then
      return current
    next  $\leftarrow$  a randomly selected successor of current
     $\Delta E \leftarrow$  VALUE(next) – VALUE(current)
    if  $\Delta E > 0$  then
      current  $\leftarrow$  next
    else current  $\leftarrow$  next only with probability  $e^{\Delta E / T}$ 
```

Übung 21. Solve instances of n-queens by hill climbing, tabu search, local beam search and simulated annealing.

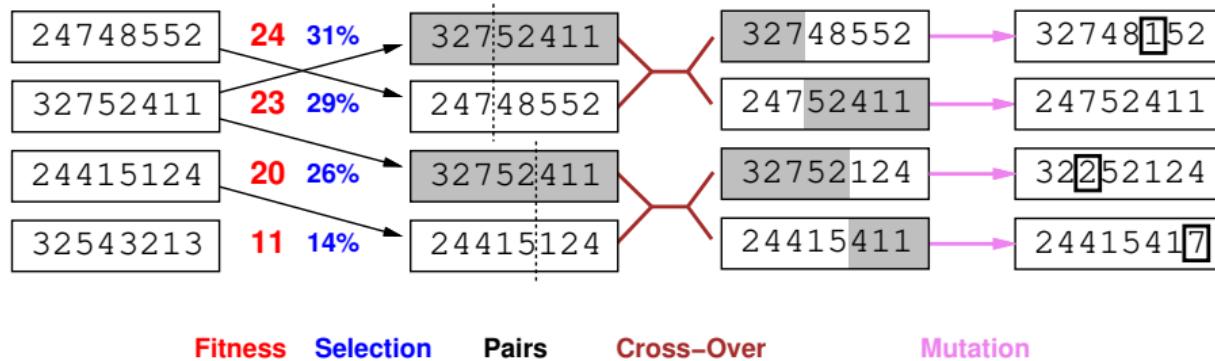
Measure the search cost and the percentage of solved problems and graph these against the optimal solution cost. Comment on your results.

stochastic beam search + generate successors from pairs of states

- GAs begin with a set of k randomly generated states, called the *population*
- each state, or *individual*, is represented as a string over a finite alphabet
- each state is rated by the evaluation function or *fitness function*
- a fitness function should return higher values for better states
for the 8-queens problem we use the number of nonattacking pairs of queens,
which has a value of 28 for a solution
- in the following example the probability of being chosen for reproducing is directly proportional to the fitness score

Genetic Algorithms

8-queens problem



- a random choice of two pairs is selected for reproduction, in accordance with the shown probabilities
- a variant of this selection rule, called *culling*, in which all individuals below a given threshold are discarded, can be shown to converge faster than the random version
- for each pair to be mated, a *crossover* point is randomly chosen from the positions in the string

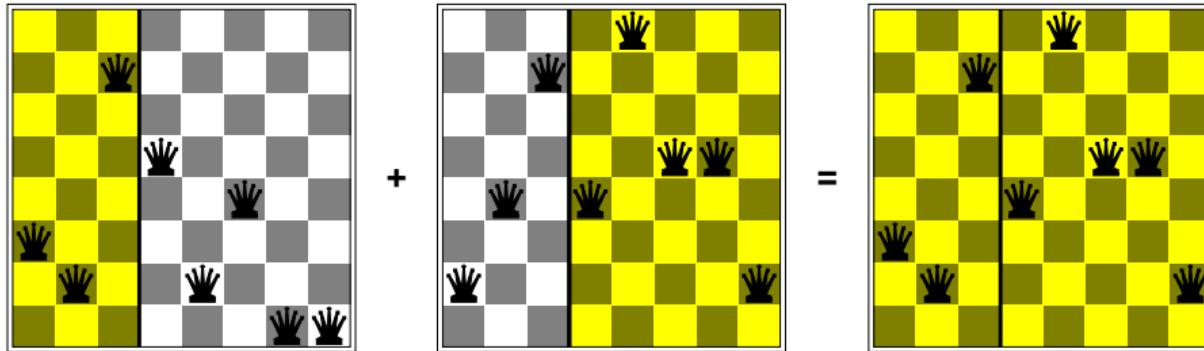
- finally, each location is subject to random mutation with a small independent probability
in the 8-queens problem, this corresponds to choosing a queen at random and moving it to a random square in its column
- primary advantage, if any, of genetic algorithms comes from the crossover operation: combine large blocks of letters that have evolved independently to perform useful functions, thus raising the level of granularity at which the search operates

GAs require states encoded as strings (GPs use programs)

- an 8-queens state must specify the positions of 8 queens, each in a column of 8 squares, and so requires $8 \times \log_2(8) = 24$ bits
- alternatively, the state could be represented as 8 digits, each in the range from 1 to 8
- behave the two encodings differently?

Genetic Algorithms

Crossover helps iff substrings are meaningful components



- *schema*: a substring in which some of the positions can be left unspecified, for example, 246****
- strings that match the schema such as 24613578 are called *instances* of the schema
- if the average fitness of the instances of a schema is above the mean, than the number of instances of the schema within the population will grow over time

- successful use of GAs require careful engineering of the representation
- at present, it is not clear whether the appeal of GAs arises from their performance or from their pleasing origins in the theory of evolution

1 Übersicht

- Informierte Suchverfahren
- Lokale Suche
- **Spiele**

2 Geschichte und Anwendungen

3 Wissensrepräsentation

4 Zustandsraumsuche

- Uninformierte Suche

5 Aussagenlogik

6 Prädikatenlogik

7 Prolog

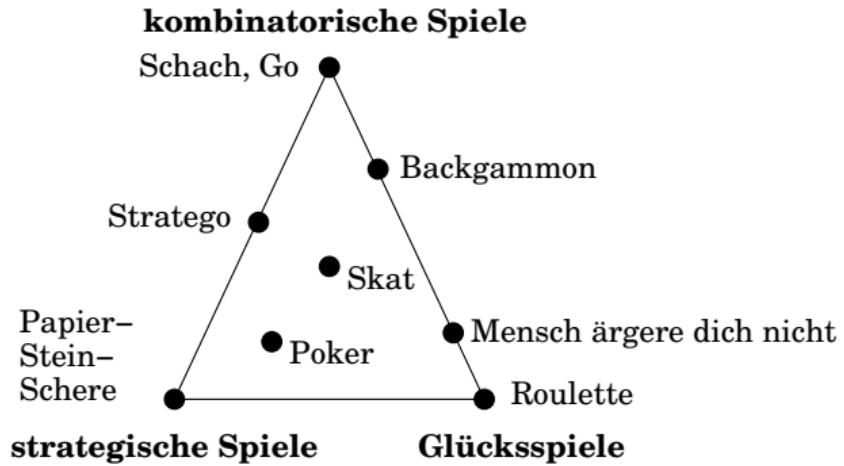
Was fasziniert uns an Spielen?

- Vor allem der ungewisse Ausgang des Spiels.

Diese Ungewissheit basiert auf

- *Zufall*: Tritt z.B. durch Würfeln (Backgammon) oder Mischen von Spielkarten (Skat) auf.
- *Kombinatorik*: Spielregeln legen die Handlungsmöglichkeiten der Spieler fest, z.B. bei Schach, Go oder Vier gewinnt.
- *mangelnder Information*: Da man z.B. nicht die Karten der Mitspieler oder deren Absichten kennt, erhält man nur eine Teilkenntnis des erreichten Spielstandes.

- *Glücksspiel*: Der Einfluss des Zufalls dominiert gegenüber denen der Spieler.
- *Kombinatorisches Spiel*: Ungewissheit beruht auf den vielfältigen, praktisch unüberschaubaren Zugmöglichkeiten.
- *Strategisches Spiel*: Ungewisser Ausgang durch imperfekte Information.

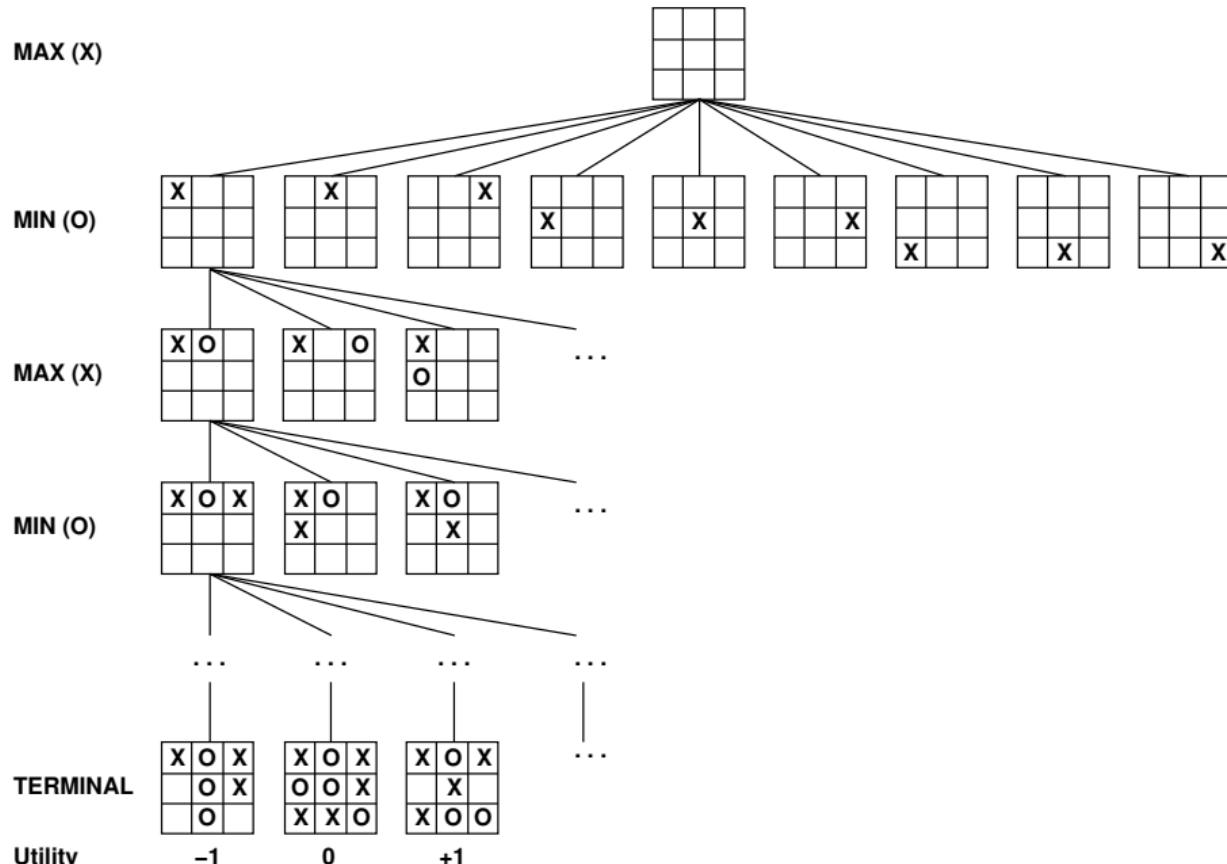


- **Zug:** Spielabschnitt, der genau eine durch die Spielregeln festgelegte Handlungsmöglichkeit eines Spielers umfasst. Wird manchmal auch Halbzug genannt.
- **Zugzwang-Phänomen:** Wenn ein Spieler nicht passen kann, verschlechtert er evtl. seine Situation durch jeden ihm möglichen Zug.
- **Kooperative Züge** stärken beide Spieler gleichzeitig (selten).
- **Nullsummenspiel:** Normalerweise fördert ein Zug den einen Spieler genauso stark, wie er den anderen behindert – die Summe der Nutzeneffekte beider Spieler ist immer gleich Null.

- Es gibt genau zwei Spieler: Max und Min.
- Max hat immer den ersten Zug.
- Es ist eine Anfangsstellung des Spiels definiert.
- Jeder Spieler besitzt die vollständige Information über die Zugmöglichkeiten des Gegners.
- Die Spieler ziehen abwechselnd, es ist kein Aussetzen möglich.
- Nach endlich vielen Zügen wird stets eine Spielstellung ohne Fortsetzungsmöglichkeiten erreicht.
- Gesucht ist eine Gewinn-Strategie für Max.
- Eine Nutzenfunktion bewertet die Endzustände und damit den Ausgang des Spiels numerisch.

win	+1	Max hat gewonnen
draw	0	unentschieden
loss	-1	Min hat gewonnen

Suchbaum für Tic-Tac-Toe



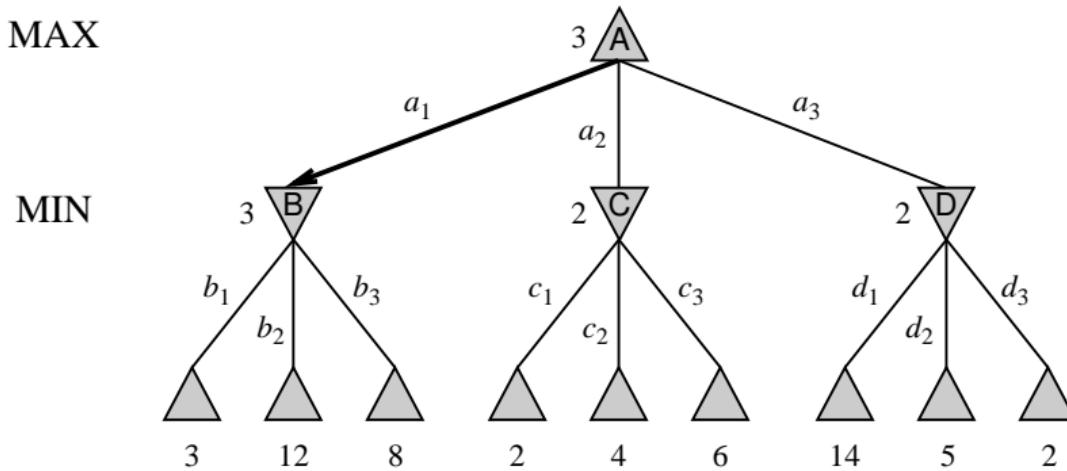
Rational agierende Spieler

- denken Zug für Zug voraus, abwechselnd einen eigenen und einen des Gegners.
- weisen den erreichbaren Positionen Werte zu: Gewinn für mich, unentschieden oder Gewinn für den Gegner.
- versuchen in jedem Zug ihren Vorteil zu maximieren, während der Gegner diesen minimieren will.

Minimax-Algorithmus

Welchen Zug muss Max machen, um zu gewinnen?

- Generiere den vollständigen Suchbaum für das Spiel.
- Wende die Nutzenfunktion auf jeden Endzustand an.
- Weise den Knoten im Suchbaum wie folgt Werte zu:
 - Ein Knoten von Max erhält als Wert das Maximum der Kinder.
 - Ein Knoten von Min erhält als Wert das Minimum der Kinder.
- Max wählt einen Zug passend zum Wert des Wurzelknotens



Minimax-Algorithmus

```
function MINIMAX-DECISION(state) : action
  inputs: state, current state in game

  v  $\leftarrow$  MAX-VALUE(state)
  return the action in SUCCESSORS(state) with value v


---


function MAX-VALUE(state) : utility value
  if TERMINAL-TEST(state) then
    return UTILITY(state)
  v  $\leftarrow$   $-\infty$ 
  for all s in SUCCESSORS(state) do
    v  $\leftarrow$  MAX(v, MIN-VALUE(s))
  return v


---


function MIN-VALUE(state) : utility value
  if TERMINAL-TEST(state) then
    return UTILITY(state)
  v  $\leftarrow$   $\infty$ 
  for all s in SUCCESSORS(state) do
    v  $\leftarrow$  MIN(v, MAX-VALUE(s))
  return v
```

Beispiel: Nim-Spiel

- Das Spiel beginnt mit einem Haufen von n Spielmarken.
- Die Spieler ziehen abwechselnd.
- Bei jedem Zug muss ein Spieler ein Häufchen Spielmarken in zwei nicht-leere, unterschiedlich große Häufchen teilen.
- Der erste Spieler, der nicht mehr ziehen kann, verliert.

Spielbaum? Minimax-Verfahren?

Eine erschöpfende Suche bis zu den Endknoten ist in der Regel nicht möglich:

- Time complexity: $\mathcal{O}(b^m)$
- Space complexity: $\mathcal{O}(b \cdot m)$ (depth-first exploration)
- for chess, $b \approx 35$, $m \approx 80$ for “reasonable” games

→ exact solution completely infeasible

- Durchsuche den Zustandsraum nur bis zu einer vordefinierten Anzahl n von Ebenen.
- Um den Wert von n festzulegen, ist der Ressourcenverbrauch für Zeit und Platz zu berücksichtigen.
- Die zu bewertenden Zustände sind dann aber in der Regel keine Endzustände.
Daher ist eine heuristische Bewertungsfunktion anzuwenden.
- Der Wert am Wurzelknoten zeigt nicht mehr an, ob das Spiel gewonnen wird!
Es handelt sich nur um den Wert des am höchsten bewerteten Zustandes, der in n Zügen vom Startknoten aus mit Sicherheit erreichbar ist.
- Diese Strategie heißt Vorausschau über n Züge.

Heuristische Bewertungsfunktion

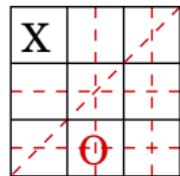
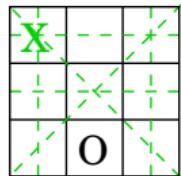
Eine heuristische Bewertungsfunktion enthält Wissen über das Spiel, um eine Stellung zu bewerten.

Beispiel: Heuristische Bewertungsfunktion für Tic-Tac-Toe.

$$Eval(z) = W(z) - L(z)$$

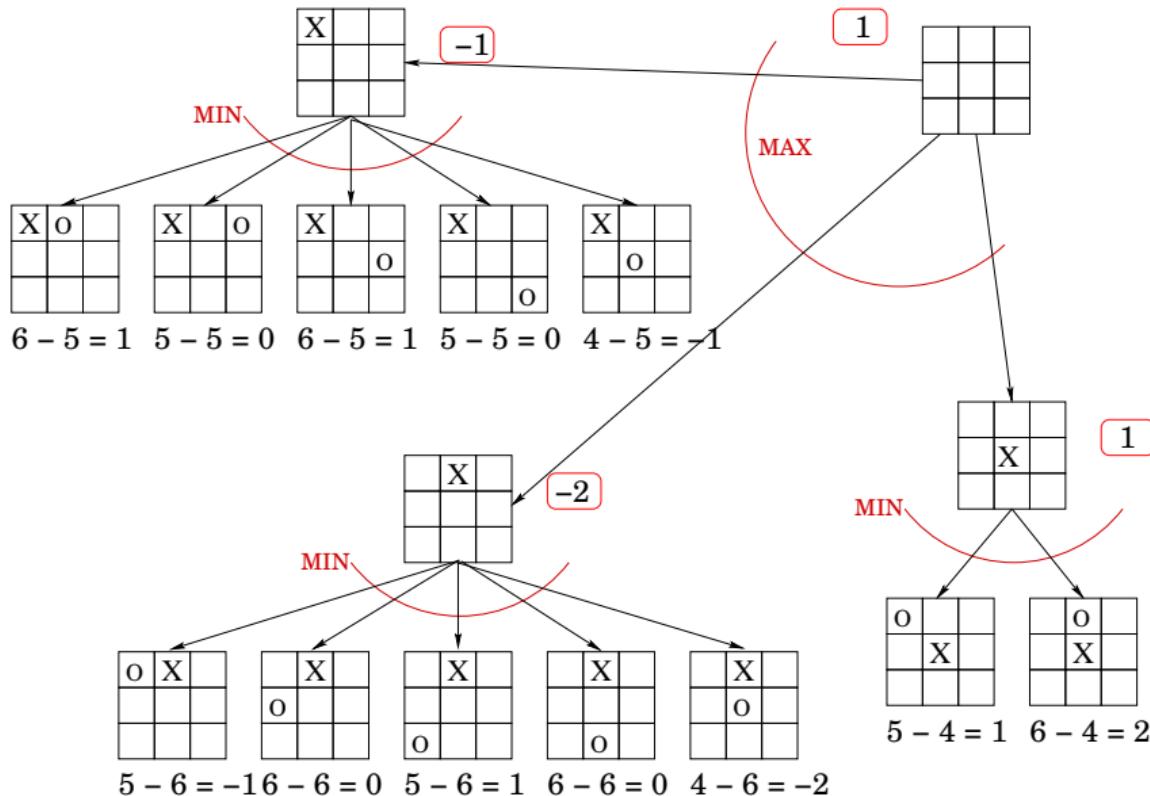
mit

- $W(z)$: Anzahl eigener Gewinnmöglichkeiten (Win).
- $L(z)$: Anzahl gegnerischer Gewinnmöglichkeiten (Loss).
- $Eval(z)$: Bewertung des Zustandes.



- X hat 6 mögliche Gewinnwege
- O hat 5 mögliche Gewinnwege

Heuristische Bewertungsfunktion



Eine Bewertungsfunktion kann auch aus n einzelnen Merkmalen bestehen, die durch eine gewichtete Summe aggregiert werden:

$$Eval(z) = w_1 \cdot f_1(z) + w_2 \cdot f_2(z) + \dots + w_n \cdot f_n(z)$$

Die Koeffizienten w_1, \dots, w_n legen fest, welche Eigenschaften wichtiger sind als andere.

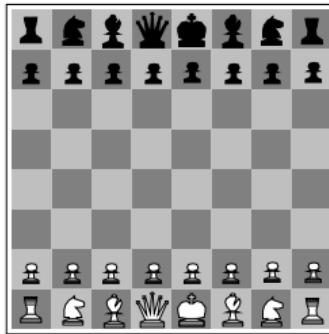
Beispiel Schach:

- $f_1(z)$ Vorteile und Position einer Figur.
- $f_2(s)$ Vorteile und Position einer anderen Figur.
- $f_3(s)$ Kontrolle über das Spielbrett usw.

Ist der Vorteil einer Dame größer als bspw. die Kontrolle über das Spielbrett, so wird der entsprechende Koeffizient erhöht.

Führt das Bewertungspolynom zu einer schlechten Zugfolge, müssen die Koeffizienten angepasst werden. → Lernen

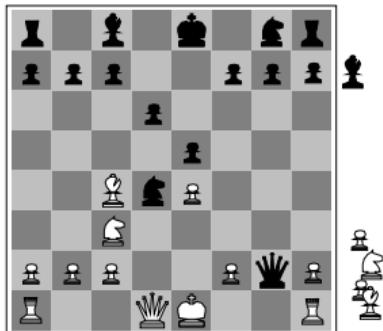
Heuristische Bewertungsfunktion



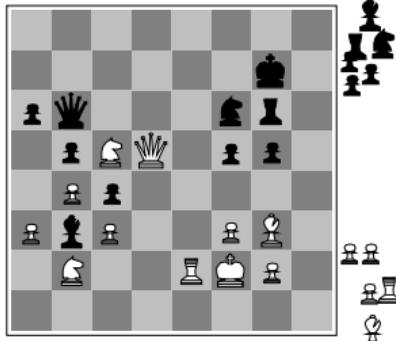
(a) White to move
Fairly even



(b) Black to move
White slightly better



(c) White to move
Black winning



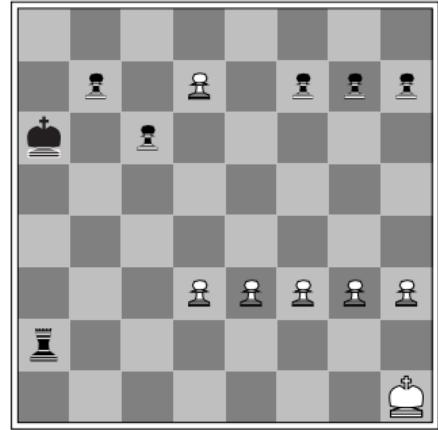
(d) Black to move
White about to lose

Horizont-Effekt

Ein Suchalgorithmus kann in gewissen Situationen zu kurzsichtig sein.

Hier: Materialvorteil für Schwarz, aber Weiß erhält eine Dame!

Besonders interessant, falls der Gegner einen für sich ungünstigen Spielzustand in wenigen Zügen jenseits der Suchtiefe in einen guten Zustand bringen kann.



Black to move

Bei begrenzter Suchtiefe kann auf der letzten Ebene das Schlagen eines gedeckten Bauern durch eine Dame günstig erscheinen, da es einen Materialvorteil bringt.

Lösung: Shannon definiert Ruhesuche, die noch heute wichtiger Bestandteil jedes Schachprogramms ist.

Zur Abschwächung des Horizontproblems wird die Ruhesuche eingesetzt.

- Eine *ruhige Position* ist dann erreicht, wenn der Gegner mit dem nächsten Zug nur eine geringe Änderung des Schätzwertes erzielen kann.

Modifiziere die Minimax-Suche mit beschränkter Tiefe:

- Relevante Blätter im Suchbaum werden durch eine Ruhesuche weitergehend analysiert.
- Zu dem so erweiterten Suchbaum wird mittels Minimax der optimale Zug bestimmt.
- Einen generellen Lösungsansatz zur Eliminierung des Horizonteffektes gibt es bisher nicht.

Ist es wünschenswert, möglichst viele Züge voraus zu schauen?

- Die Bewertungen, die sehr tief im Baum stattfinden, können durch die bloße Tiefe negativ beeinflusst werden.
- Eine Schätzung von Minimax (das wünschen wir uns) ist etwas anderes als das Minimax von Schätzungen (das tun wir).
 - Eine tiefere Suche mit Bewertung und Minimax bedeutet nicht unbedingt, dass dies die bessere Suche ist.

Minimax von Schätzungen:

- Bewertungsfunktionen sind nur Heuristiken und daher fehlerhaft.
 - Ist eine kleinere Tiefe besser, weil weniger Fehler akkumuliert werden?
- Ruhe-Suche nach Shannon
 - Eine tiefere Suche kann den Horizonteffekt abschwächen.

A. Sadikov, I. Bratko, I. Kononenko. Bias and pathology in minimax search. Theoretical Computer Science 349(2), 2005.

Abstract⁽⁶⁵⁾: „Dieser Artikel präsentiert die Ergebnisse von Experimenten, die darauf abzielen, Erkenntnisse über die Auswirkungen des Minimax-Algorithmus auf den Fehler einer heuristischen Bewertungsfunktion zu gewinnen. Es werden zwei Arten von Auswirkungen des Minimax-Algorithmus betrachtet.

- Bewertungsgenauigkeit: Sind die durch Minimax gestützten Werte genauer als die heuristischen Werte selbst?
- Entscheidungsgenauigkeit: Sind Züge, die durch eine tiefere Minimax-Suche gespielt werden, besser als solche, die durch eine flachere Suche gespielt werden?

Die Experimente wurden im Schachendspiel König-Turm-König (KRK) und in zufällig generierten Spielbäumen durchgeführt. Die Ergebnisse zeigen, dass die Bewertungsgenauigkeit entgegen der Intuition mit zunehmender Suchtiefe abnehmen kann, während sich gleichzeitig die Entscheidungsgenauigkeit mit zunehmender Tiefe verbessert.“

⁽⁶⁵⁾übersetzt mit deepL

M. Guid, I. Bratko. Influence of Search Depth on Position Evaluation. Advances in Computer Games, 2017.

Abstract⁽⁶⁶⁾: „Anhand eines bekannten Schachprogramms und eines großen Datensatzes mit Schachstellungen aus realen Partien zeigen wir empirisch, dass mit zunehmender Suchtiefe die Bewertungen von gewonnenen Stellungen tendenziell steigen, während die Bewertungen von verlorenen Stellungen tendenziell sinken.“

Damit unterstützt dieses Paper die Vermutung, dass größere Tiefe zu signifikanteren Bewertungsunterschieden führt.

⁽⁶⁶⁾übersetzt mit deepL

Dana S. Nau. Decision Quality As a Function of Search Depth on Game Trees. Journal of the ACM 30(4), 1983.

Abstract: „[...] Forscher im Bereich der künstlichen Intelligenz haben gute Ergebnisse erzielt, indem sie den Baum bis zu einer beliebigen Tiefe durchsucht und eine statische Bewertungsfunktion verwendet haben, um die Werte der Knoten in dieser Tiefe zu schätzen. Es wird allgemein angenommen, dass sich in diesem Fall die Qualität der Entscheidung mit zunehmender Suchtiefe verbessert. Diese Annahme basiert ausschließlich auf empirischen Beweisen.“

Der Autor hat eine mathematische Theorie entwickelt, die die Auswirkungen der Suchtiefe auf die Wahrscheinlichkeit einer richtigen Entscheidung modelliert. In dieser Theorie werden die Fehler der Bewertungsfunktion als unabhängige, identisch verteilte Zufallsfehler modelliert, die den tatsächlichen Werten der bewerteten Knoten überlagert sind. Diese Forschung hat zu dem überraschenden Ergebnis geführt, dass es eine unendliche Klasse von Spielbäumen gibt, bei denen eine tiefere Suche die Wahrscheinlichkeit einer richtigen Entscheidung nicht erhöht, sondern stattdessen dazu führt, dass die Entscheidung immer zufälliger wird. [...]“

Warum kann es sinnvoll sein, die Suchtiefe möglichst groß zu wählen?

- Je tiefer die Suche, umso mehr „echte“ Endzustände werden erreicht. Dadurch wird die Min- bzw. Max-Auswertung genauer. (siehe nächste Seite)
- Mehr künftige Spielzüge und deren Konsequenzen werden berücksichtigt.
- Die Heuristik wird auf tiefere, konkretere Spielsituationen angewendet, die tendentiell besser durch die Heuristik erkannt werden. → weniger Horizont-Effekte
- Werden Endspieldatenbanken genutzt, dann werden durch eine große Suchtiefe Zustände erreicht, die exakt bewertet sind (Matt in 12 Zügen) und so genauere Min- bzw. Max-Auswertungen liefern.

(zu) einfache Bewertungsfunktion bei Schach:

- Werte der Figuren: Dame = 8, Turm = 5, Läufer = 3, Springer = 2, Bauer = 1
- Heuristik: Summe eigene Figuren - Summe gegnerische Figuren
- Terminalzustände $\pm\infty$

Betrachten wir auch eine (zu einfache) Bewertungsfunktion bei 4-Gewinnt.

Alpha-Beta-Suche

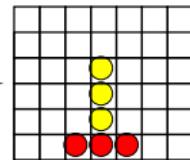
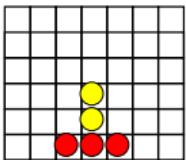
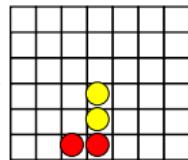
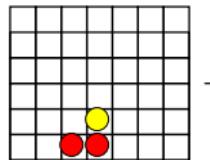
Beispiel: Wir ordnen jedem Feld die Anzahl der möglichen Gewinnreihen zu. Die Bewertungsfunktion addiert die Werte der Felder, die mit eigenen Spielsteinen belegt sind und subtrahiert die Werte der Felder, die mit gegnerischen Steinen belegt sind.

Bei einer Suchtiefe von drei wird nicht erkannt, dass der Spieler rot das Spiel gewinnen kann, was auf jeden Fall verhindert werden muss.

3	4	5	7	5	4	3
4	6	8	9	8	6	4
5	8	11	13	11	8	5
5	8	11	13	11	8	5
4	6	8	9	8	6	4
3	4	5	7	5	4	3

3	4	5	7	5	4	3
4	6	8	9	8	6	4
5	8	11	13	11	8	5
5	8	11	13	11	8	5
4	6	8	9	8	6	4
3	4	5	7	5	4	3

3	4	5	7	5	4	3
4	6	8	9	8	6	4
5	8	11	13	11	8	5
5	8	11	13	11	8	5
4	6	8	9	8	6	4
3	4	5	7	5	4	3



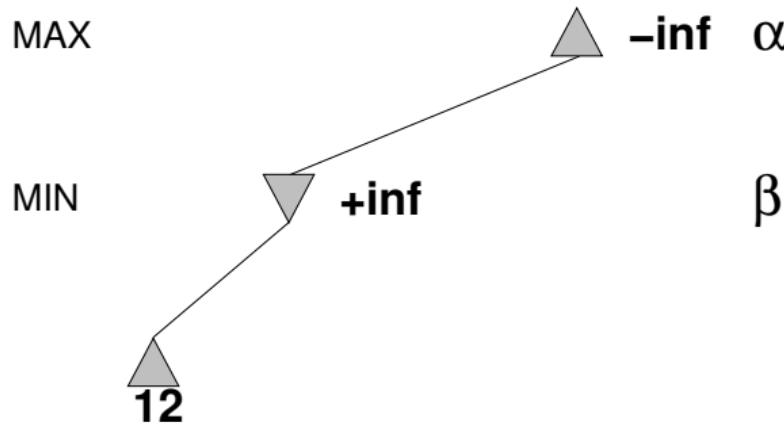
Durch eine größere Suchtiefe werden fehlerhafte Bewertungen evtl. abgeschwächt.

Wir wollen mittels Branch-and-Bound die Suchtiefe steigern, indem Teilbäume, die kein besseres Ergebnis als das bisher beste liefern können, abgeschnitten werden.

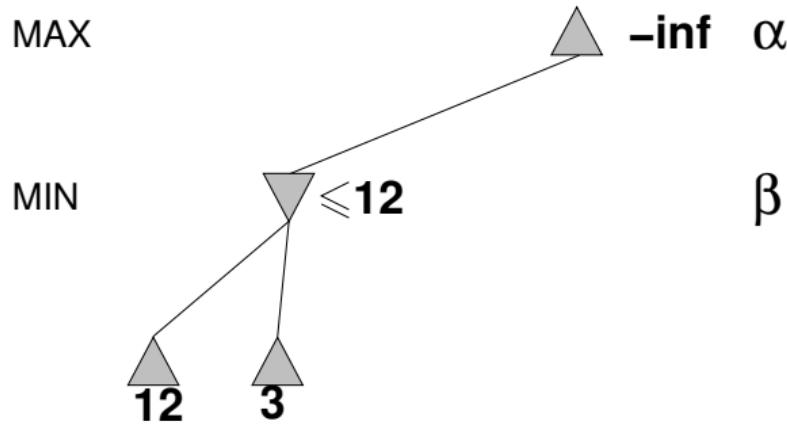
- Für die Berechnung der Minimax-Bewertung irrelevante Zweige werden nicht weiter untersucht.
- Wir benötigen zunächst die Bewertungen der Zustände in der maximalen Suchtiefe, also setzen wir Tiefensuche ein.
- Legen vorläufige Bewertungen fest:
 - Alpha-Werte sind Werte an Max-Knoten.
 - Alpha-Werte können niemals kleiner werden!
 - Beta-Werte sind Werte an Min-Knoten.
 - Beta-Werte können niemals größer werden!
- Diese Werte steuern das vorzeitige Beenden der Suche in einem Teilbaum.
- Wir können die Suche unterhalb eines Max-Knotens s vorzeitig beenden, wenn gilt:

$$\exists \text{Min-Vorgänger } s' \text{ von } s : \alpha(s) \geq \beta(s')$$

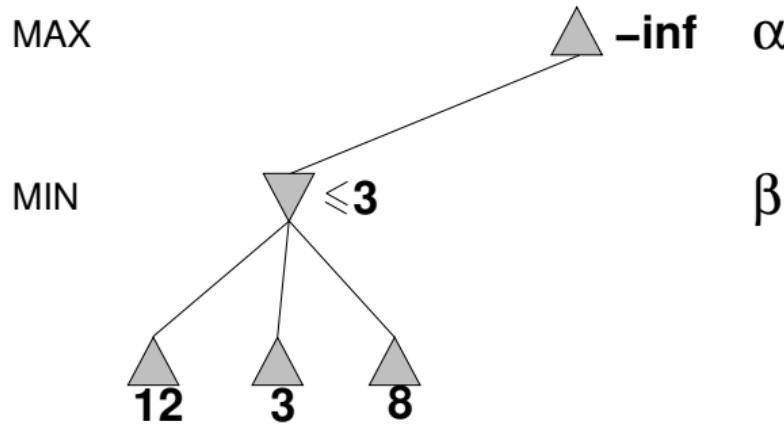
- analoge Definition für Min-Knoten (siehe nächste Folien)



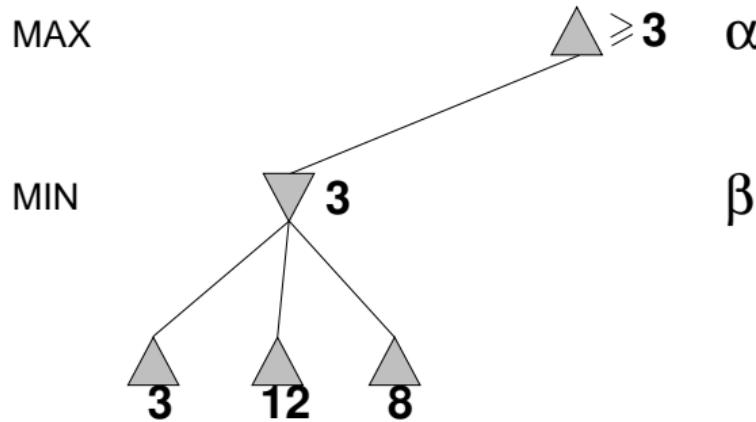
β -Werte können nicht größer werden!



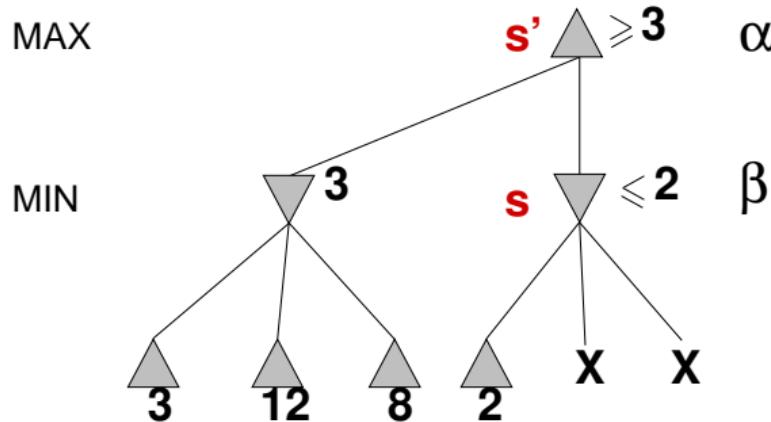
β -Werte können nicht größer werden!



β -Werte können nicht größer werden!



α -Werte können nicht kleiner werden!

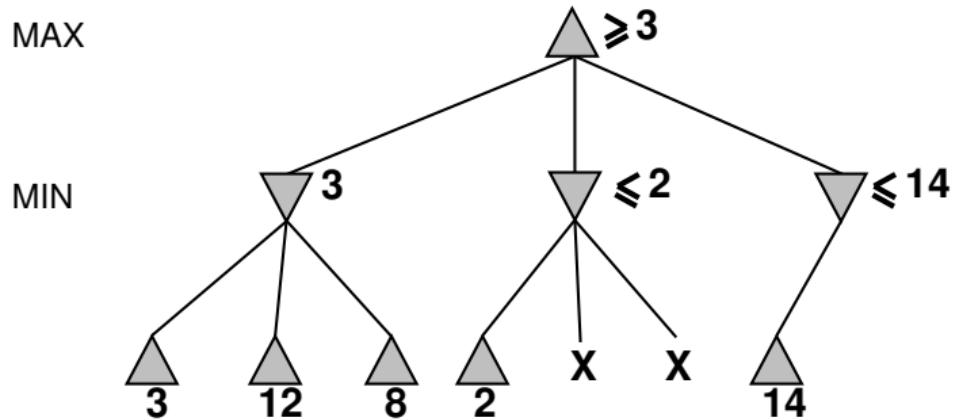


Suche unterhalb des Min-Knotens s vorzeitig beenden, wenn gilt:

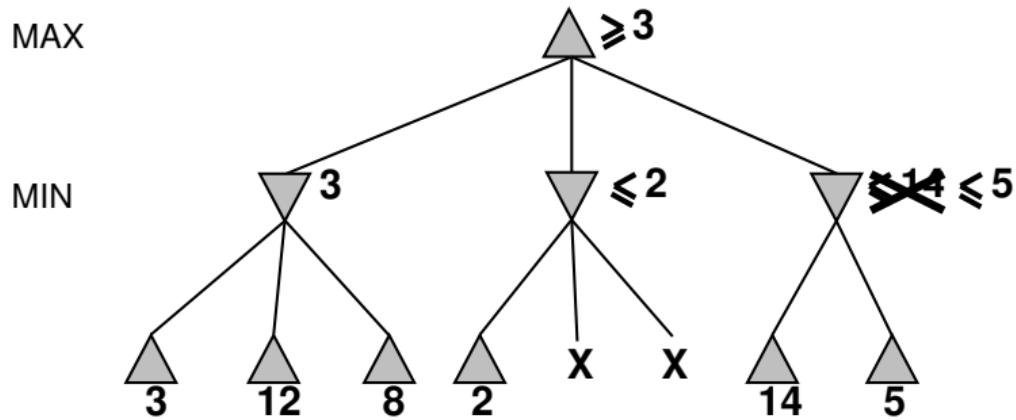
$$\exists \text{Max-Vorgänger } s' \text{ von } s : \beta(s) \leq \alpha(s')$$

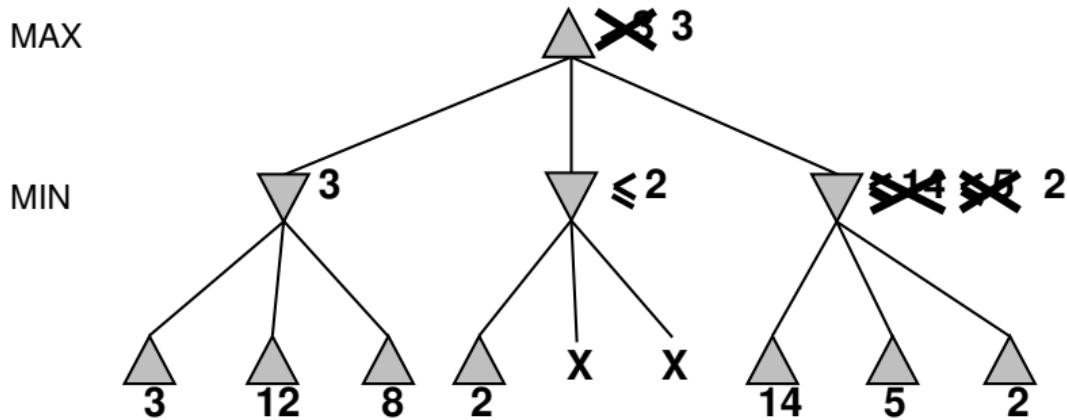
Im Zustand s' wird ein Maximum gebildet, das bereits jetzt größer als der Wert $\beta(s)$ ist. Da $\beta(s)$ nicht größer als 2 werden kann, wird die Bearbeitung des Teilbaums unter s abgebrochen.

Alpha-Beta-Suche



Alpha-Beta-Suche





Offensichtlich spielt die Reihenfolge, in der Kindknoten bearbeitet werden, eine wesentliche Rolle. Daher ist es wichtig, zuerst die Züge zu betrachten, die aus der Sicht des jeweiligen Spielers das beste Ergebnis versprechen.

Setze Heuristik ein: Sortiere beim Schach die Züge danach, welche Figur geschlagen wird, oder welche Figur schlägt. „Turm schlägt Dame“ vor „Bauer schlägt Turm“ vor „Turm schlägt Turm“.

Alpha-Beta-Suche

```
function ALPHA-BETA-DECISION(state) : action
```

inputs: *state*, current state in game

```
v ← MAX-VALUE(state,  $-\infty$ ,  $+\infty$ )
```

```
return the action in SUCCESSORS(state) with value v
```

```
function MAX-VALUE(state,  $\alpha$ ,  $\beta$ ) : utility value
```

inputs: *state*, current state in game

α , the value of the best alternative for MAX along the path to *state*

β , the value of the best alternative for MIN along the path to *state*

```
if TERMINAL-TEST(state) then return UTILITY(state)
```

```
v ←  $-\infty$ 
```

```
for all s in SUCCESSORS(state) do
```

```
  v ← MAX(v, MIN-VALUE(s,  $\alpha$ ,  $\beta$ ))
```

```
  if v  $\geq \beta$  then return v
```

```
   $\alpha$  ← MAX( $\alpha$ , v)
```

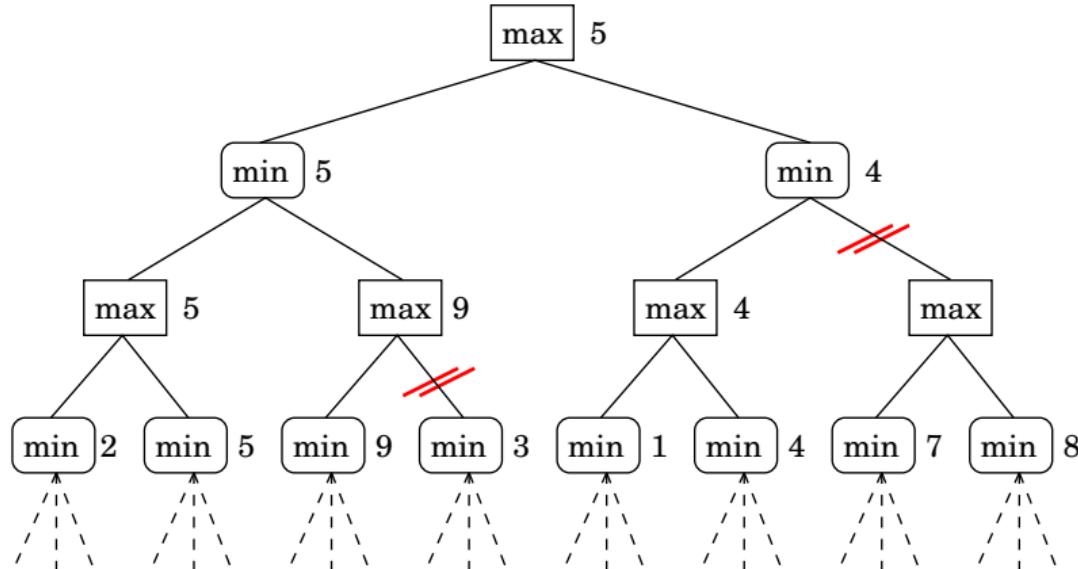
```
return v
```

```
function MIN-VALUE(state,  $\alpha$ ,  $\beta$ ) : utility value
```

same as MAX-VALUE but with roles of α , β reversed

Alpha-Beta-Suche

Ein Beispiel mit α - und β -Cut:



Bei einer perfekten Zugreihenfolge⁽⁶⁷⁾⁽⁶⁸⁾ müsste Alpha-Beta nur $\mathcal{O}(b^{m/2})$ Knoten untersuchen, um den besten Zug auszuwählen, anstatt $\mathcal{O}(b^m)$ wie bei Minimax. Das bedeutet, dass der effektive Verzweigungsfaktor \sqrt{b} statt b wird - beim Schach etwa 6 statt 35, bei Go etwa 16 statt 235.

- Alpha-Beta mit perfekter Zugreihenfolge kann einen Baum, der etwa doppelt so tief ist wie Minimax, in derselben Zeit lösen.

Bei zufälliger Zugreihenfolge beträgt die Gesamtzahl der untersuchten Knoten für moderates b ungefähr $\mathcal{O}(b^{3m/4})$.

Es kann keine perfekte Zugreihenfolge erreicht werden - in diesem Fall könnte die Reihenfolgefunktion verwendet werden, um ein perfektes Spiel zu spielen! Aber bspw. bei Schach führt eine relativ einfache Reihenfolgefunktion (z.B. zuerst Schläge, dann Drohungen, dann Vorwärtszüge und dann Rückwärtszüge) zu einem Ergebnis, das um etwa den Faktor 2 vom besten Fall entfernt ist.

⁽⁶⁷⁾D.E. Knuth, R.W. Moore. An analysis of alpha-beta pruning. *Artificial Intelligence* 6(4), 1975.

⁽⁶⁸⁾G.M. Baudet. An analysis of the full alpha-beta pruning algorithm. *Proceedings of ACM Symposium on Theory Of Computing*, 1978.

Durch Hinzufügen *dynamischer Zugreihenfolge-Schemata*, wie bspw. das Ausprobieren der Züge, die sich in der Vergangenheit als die besten erwiesen haben, kommen wir der theoretischen Grenze ziemlich nahe. Die Vergangenheit kann der vorherige Zug sein - oft bleiben die gleichen Bedrohungen bestehen - oder sie kann aus der vorherigen Erkundung des aktuellen Zuges durch einen Prozess des *iterative deepening* stammen.

→ Suche zunächst eine Ebene tief und zeichne die Rangfolge der Züge anhand ihrer Bewertungen auf. Suche dann eine Ebene tiefer und verwende die vorherige Rangfolge, um die Zugreihenfolge zu bestimmen, und so weiter.

Die durch die iterative Vertiefung erhöhte Suchzeit kann durch eine bessere Zugreihenfolge mehr als ausgeglichen werden. Die besten Züge werden als Killerzüge bezeichnet, und sie zuerst auszuprobieren, wird als Killerzug-Heuristik bezeichnet:

Guter Zug in einem Teilbaum $\stackrel{?}{=}$ guter Zug in einem anderen Teilbaum.

Grundidee der *Killerzug-Heuristik*: Basiert auf der Beobachtung, dass bestimmte Züge - sogenannte „Killerzüge“ - in einer bestimmten Suchtiefe häufig dazu führen, dass andere Zweige des Suchbaums abgeschnitten werden (engl. cutoff). Diese Züge haben sich also bereits als sehr effektiv bei der Alpha-Beta-Suche erwiesen.

Statt jeden möglichen Zug in beliebiger Reihenfolge zu untersuchen, versucht das Programm bei gleicher Suchtiefe zuerst die Killerzüge, in der Hoffnung, dass auch diesmal schnell ein Cutoff erfolgt. Das spart Rechenzeit.

Technische Umsetzung:

- Für jede Suchtiefe wird eine kleine Liste (oft 1 oder 2) von Killerzügen gespeichert.
- Wenn ein Zug bei der Suche einen Cutoff verursacht (also den Suchzweig beendet), wird dieser Zug als Killerzug für diese Tiefe gespeichert.
- In zukünftigen Suchvorgängen wird dieser Killerzug bevorzugt geprüft - noch vor „normalen“ Zügen wie etwa Bauernzüge oder Züge ohne Materialgewinn.

Wir hatten auf Seite 388 festgestellt, dass redundante Pfade zu wiederholten Zuständen zu einem exponentiellen Anstieg der Suchkosten führen können und dass dieses Problem durch die Führung einer Tabelle mit zuvor erreichten Zuständen gelöst werden kann. Bei der Spielbaumsuche können wiederholte Zustände aufgrund von Transpositionen auftreten - also unterschiedlichen Permutationen der Zugsequenz, die zum gleichen Zustand führen. Dieses Problem kann mit einer *Transpositionstabelle* gelöst werden, in der der heuristische Wert der Zustände zwischengespeichert wird.

Beispiel: Weiß macht Zug w_1 , auf den Schwarz mit b_1 antwortet, dann macht Weiß einen unabhängigen Zug w_2 auf der anderen Seite des Bretts, auf den Schwarz mit b_2 antwortet: Zugfolge $[w_1, b_1, w_2, b_2]$ erreicht Zustand s . Nachdem ein großer Teilbaum unterhalb von s untersucht wurde, wird die gesicherte Bewertung $h(s)$ in der Transpositionstabelle gespeichert. Wenn später die Zugfolge $[w_2, b_2, w_1, b_1]$ untersucht wird, also Zustand s erreicht wird, kann der Wert aus der Tabelle genutzt werden, anstatt die Suche zu wiederholen.

Im Schach ist die Verwendung von Transpositionstabellen sehr effektiv, da wir damit die erreichbare Suchtiefe in derselben Zeit etwa verdoppeln können.

Übung 22. Implementieren Sie den Minimax-Algorithmus und die Alpha-Beta-Suche für ein Spiel wie Vier-Gewinnt⁽⁶⁹⁾ oder Reversi bzw. Othello⁽⁷⁰⁾.

Vergleichen Sie die Laufzeiten beider Verfahren bei gleicher Suchtiefe.

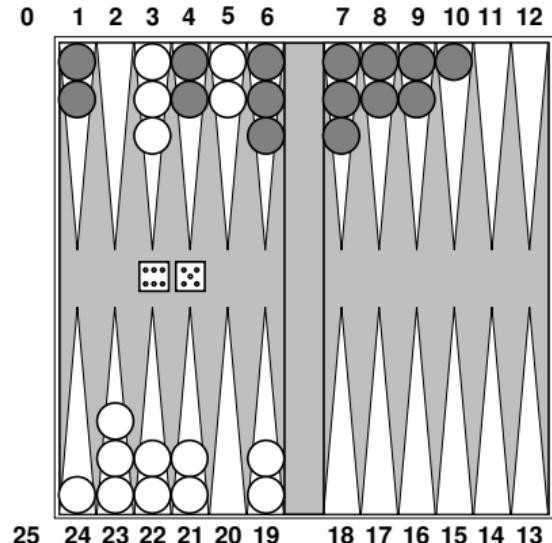
⁽⁶⁹⁾<https://wiki.neuro.tu-berlin.de/home/teaching/2024ws-AlgoDat-SE/WikiGames/>

⁽⁷⁰⁾<https://de.wikipedia.org/wiki/Computer-Othello>

engl.: nondeterministic games

Zufall in Spielen entsteht bspw. durch Würfeln (Backgammon) oder durch Mischen und unbekannter Kartenverteilung (Skat).

Im Gegensatz zu rein kombinatorischen Spielen kann eine gute Stellung durch ungünstiges Würfeln oder eine schlechte Kartenverteilung nutzlos sein.



Können wir das Minimax-Prinzip auf solche Spiele übertragen?

Was ändert sich durch das Einbringen von Zufallselementen?

- Ein Spieler kann nicht mehr von einem garantierten Nutzen einer Strategie ausgehen. Die angewendete Strategie ist oft gut, kann aber im Einzelfall, also z.B. bei ungünstigem Würfeln fehlschlagen.

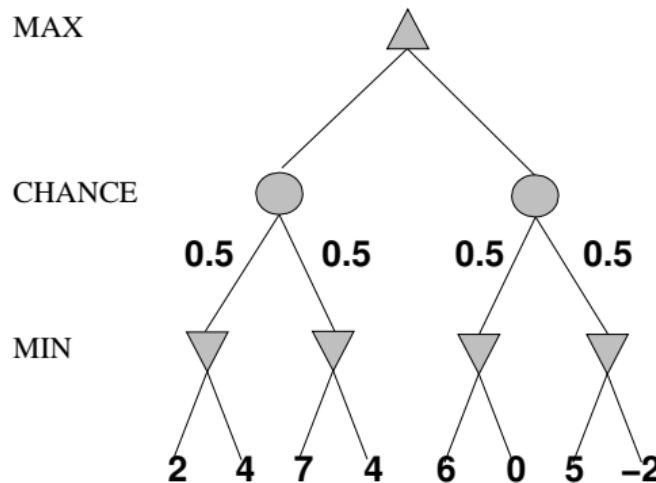
Wie gehen wir damit um?

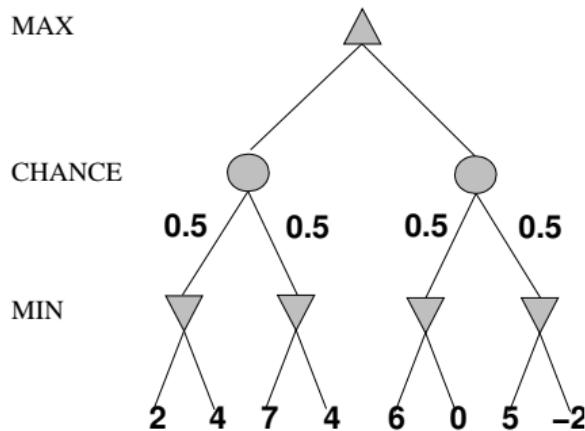
- Bewerte eine Strategie oder auch einen einzelnen Zug mit dem durchschnittlichen Nutzen: Erwartungswert
- Ein Zufallsereignis \mathcal{X} kann zu den Gewinnen x_1, \dots, x_n führen.
- $P(\mathcal{X} = x_i)$: Wahrscheinlichkeit, mit der Gewinn x_i auftritt.
- Erwartungswert $E(\mathcal{X})$ des Zufallsereignisses \mathcal{X} :

$$E(\mathcal{X}) = \sum_{i=1}^n x_i \cdot P(\mathcal{X} = x_i)$$

Neben den möglichen Zügen müssen wir nun im Spielbaum für die Bewertung eines Zuges die Zufallskomponente berücksichtigen:

- Zufallsereignisse werden als Knoten repräsentiert.
- Von einem Zufallsknoten ausgehende Kanten sind mit der Wahrscheinlichkeit markiert, mit der der jeweilige Nachfolgezustand erreicht wird.



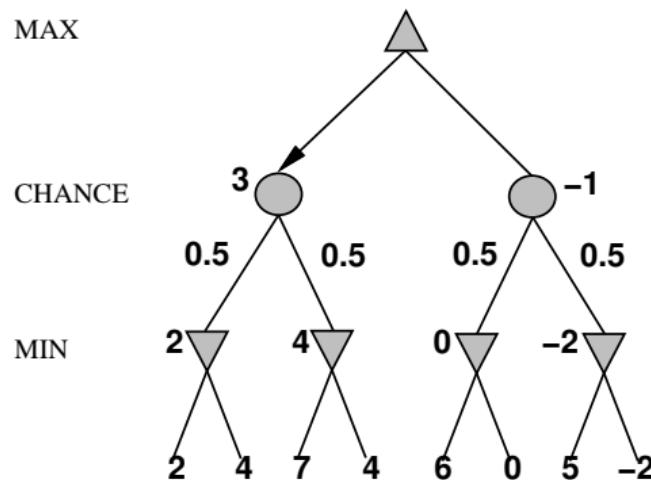


- Die Wurzel repräsentiert sowohl eine Spielsituation als auch die letzte Zufallsentscheidung, hier einen Münzwurf.
- Die Kanten zu den Chance-Knoten stellen mögliche Spielzüge dar.
- Chance-Knoten repräsentieren Spielsituationen bzw. Zustände.

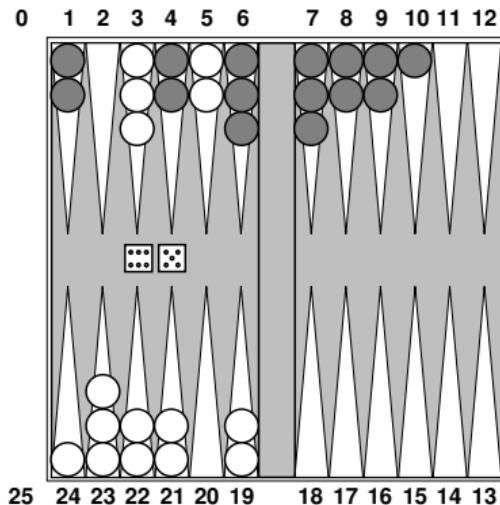
- Min- und Max-Knoten (außer die Wurzel) repräsentieren keine Zustände!
- Ein Chance-Knoten kann einen terminalen Zustand repräsentieren.
- Endknoten und Max- und Min-Knoten funktionieren genau wie zuvor, aber mit der Einschränkung, dass die zulässigen Züge für Max und Min vom Ergebnis der Zufallsentscheidung im vorherigen Zufallsknoten abhängen.

An Zufallsknoten berechnen wir den zugehörigen Erwartungswert:

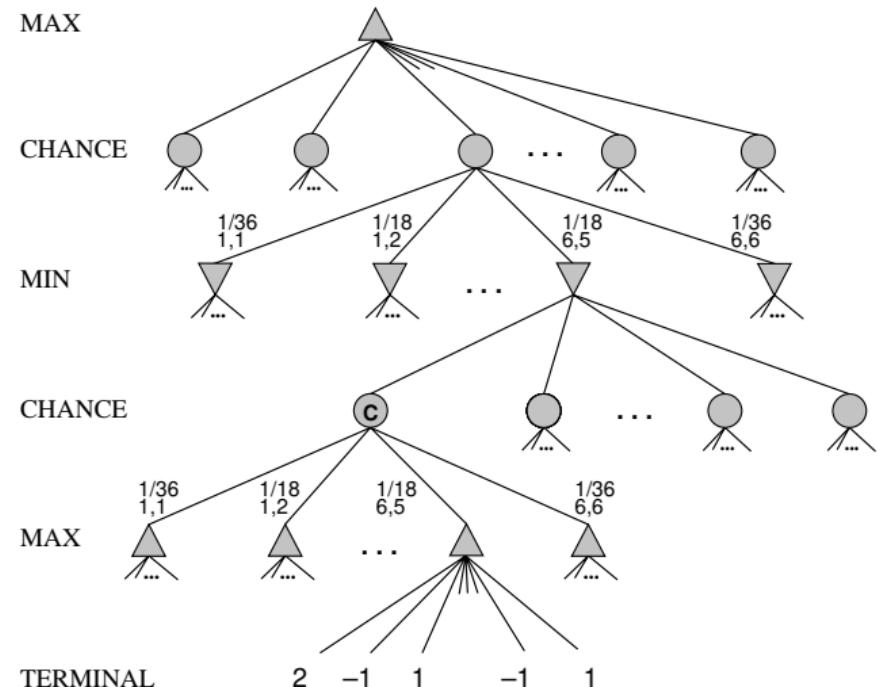
- Die x_i entsprechen den Bewertungen der Kinder,
- die Wahrscheinlichkeiten $P(\mathcal{X} = x_i)$ ergeben sich durch die Markierungen der Kanten.



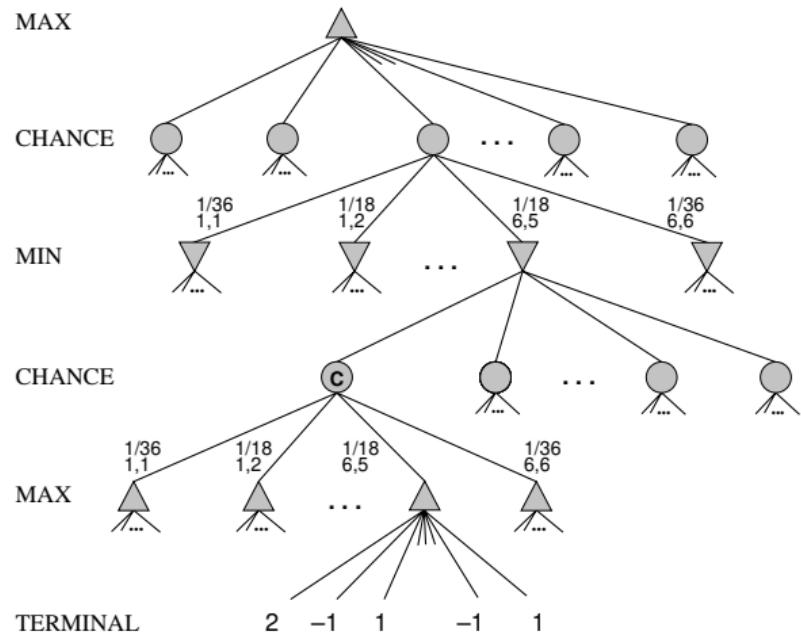
Kombinatorische Spiele mit Zufallselementen



Ausgangssituation für Max:
Spielbrett und Würfel sind
bekannt, damit ergeben sich
mehrere mögliche Züge für
Max.



- erste Ebene: mögliche Züge für weiß sind (5-10, 10-16), (5-10, 5-11), (5-11, 11-16) und (5-11, 19-24)
- erste Ebene Chance-Knoten repräsentiert Zustände nach dem ersten Zug
- Die Kanten von den Chance- zu den Min-Knoten stellen das Würfeln von Min dar.
- Nach dem Würfeln ergeben sich wieder mehrere konkrete Züge für Min.
- zweite Ebene Chance-Knoten repräsentiert Zustände nach dem Zug von Min



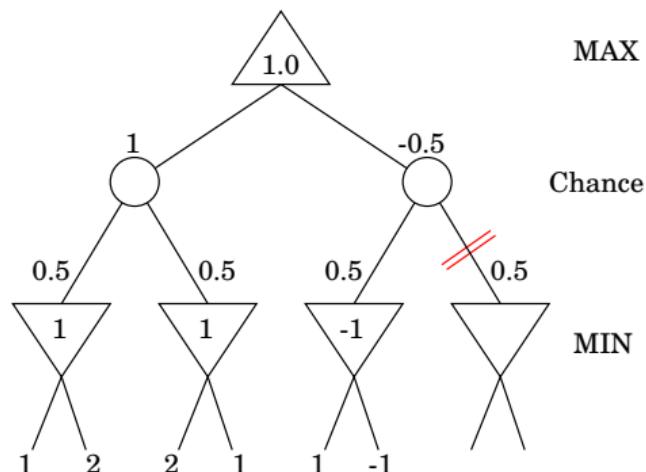
Expecti-Minimax⁽⁷¹⁾

```
function EXPECTIMINIMAX(node, depth)
    if node is a terminal node or depth = 0 then
        return the heuristic value of node
    if the adversary is to play at node then
        let res := +∞                      ▷ Return value of minimum-valued child node
        for all child of node do
            res := min(res, EXPECTIMINIMAX(child, depth-1))
    else if we are to play at node then
        let res := -∞                      ▷ Return value of maximum-valued child node
        for all child of node do
            res := max(res, EXPECTIMINIMAX(child, depth-1))
    else if random event at node then
        let res := 0                        ▷ Return weighted average of all child nodes' values
        for all child of node do
            res := res + (Probability[child] · EXPECTIMINIMAX(child, depth-1))
    return res
```

⁽⁷¹⁾<https://en.wikipedia.org/wiki/Expectiminimax>

Alpha-Beta-Pruning bei Expecti-Minimax

- alpha-beta pruning could be applied to game trees with chance nodes
- analysis for MIN and MAX nodes is unchanged
- we can also prune chance nodes, using a bit of ingenuity
- if we put bounds on the possible values of the utility function, then we can arrive at bounds for the average without looking at every number



Ist die Bewertungsfunktion im rechten Beispiel auf Werte aus dem Intervall $(-2, +2)$ beschränkt, dann kann der Wert im rechten Chance-Knoten nur noch maximal $-1 \cdot 1/2 + 2 \cdot 1/2 = 0.5$ werden.

Der rechteste Min-Knoten muss also gar nicht untersucht werden, da der Wert im Max-Knoten bereits größer als der noch zu erreichende Wert 0.5 ist.

1 Übersicht

2 Geschichte und Anwendungen

3 Wissensrepräsentation

4 Zustandsraumsuche

5 Aussagenlogik

6 Prädikatenlogik

7 Prolog

1 Übersicht

2 Geschichte und Anwendungen

3 Wissensrepräsentation

4 Zustandsraumsuche

5 Aussagenlogik

- Grundbegriffe
- Äquivalenz und Normalformen
- Hornformeln
- Resolution

6 Prädikatenlogik

7 Prolog

Unter einer *Aussage* versteht man ein atomares sprachliches Gebilde, das einen der beiden *Wahrheitswerte* wahr oder falsch hat.

Wahre Aussagen:

- Krefeld liegt am Rhein.
- Es gibt unendlich viele Primzahlen.
- $3 + 4 = 7$

Falsche Aussagen:

- Duisburg liegt an der Elbe.
- Die Erde ist eine Scheibe.
- $3 + 4 = 8$

Aussagen, von denen wir zum jetzigen Zeitpunkt nicht wissen, ob sie wahr oder falsch sind:

- Es gibt außerirdisches Leben.
- $P \neq NP$

Es wird letztlich ignoriert, welche inhaltlichen Bedeutungen vorliegen, unser Interesse wird auf die Wahrheitswerte reduziert:

- A : Otto wird krank
- B : der Arzt verschreibt Otto eine Medizin

Da wir in der Umgangssprache oft einen zeitlichen und kausalen Ablauf voraussetzen, unterscheiden wir umgangssprachlich:

A und B „Otto wird krank und der Arzt verschreibt Otto eine Medizin“

B und A „der Arzt verschreibt Otto eine Medizin und Otto wird krank“

Von solchen Feinheiten befreien wir uns im Folgenden.

Gegenstand der Aussagenlogik:

- Untersuche einfache Verknüpfungen wie *und*, *oder* und *nicht*, zwischen Aussagen und
- lege fest, wie sich Wahrheitswerte der atomaren Bestandteile zu Wahrheitswerten von komplizierteren sprachlichen Gebilden fortsetzen lassen.

Inferenz:

- Herleiten von neuem Wissen auf Basis eines Kalküls.
- Definition des Folgerungsbegriffs.
- Übertragen der semantischen Folgerung auf äquivalente syntaktische Umformungen.

- *Prognosen bzw. logische Ableitungen erstellen:*

Wenn Fakten und Regeln gegeben sind, welche Folgerungen kann man daraus ziehen?

- *Erklärungen finden:*

Wie lässt sich ein Fakt mittels der Regeln erklären?

- *Hypothesen prüfen:*

Können aus den Fakten und Regeln die Hypothesen hergeleitet werden?

Es gibt verschiedene Arten von Schlussfolgerungen⁽⁷²⁾.

Deduktion: Schließe vom allgemeinen Fall auf einen speziellen Fall. Ist immer mit der Vorstellung verbunden, dass es sich um korrekte Schlussfolgerungen handelt, dass das abgeleitete Wissen also stets wahr ist.

Beispiele:

Vögel können fliegen.

Max ist ein Vogel.

Max kann fliegen.

Alle Holländer essen gern Käse.

Hans ist Holländer.

Hans isst gerne Käse.

⁽⁷²⁾ Schlussfolgerung wird in der Informatik meist als Inferenz bezeichnet.

Induktion: Man erschließt regelhaftes Wissen aus einzelnen Sachverhalten. Nur so kann man sich weiträumig anwendbare Tatsachen über die wirkliche Welt erschließen. Sonst hätten wir nur Millionen von Einzelerfahrungen.

Allerdings geben wir dabei die Vorstellung auf, das neu abgeleitetes Wissen auch stets wahr ist.

Beispiel:

Bello ist ein Hund, Bello bellt, Bello beißt nicht.

Trixi ist ein Hund, Trixi bellt, Trixi beißt nicht.

Waldi ist ein Hund, Waldi bellt, Waldi beißt nicht.

Hunde, die bellen, beißen nicht. (???)

Abduktion: Wir suchen nach einer Erklärung für unsere Beobachtungen, wir bilden Hypothesen. Alle Diagnoseverfahren in der Medizin oder Technik basieren auf Abduktion.

Auch hier ist das abgeleitete Wissen nicht notwendig wahr.

Beispiel:

Max hat lange Ohren.	Beobachtung
Hasen haben lange Ohren.	Wissen
Max ist ein Hase. (???)	Schlussfolgerung

Jeder wissenschaftliche Erkenntnisprozess entsteht aus dem Zusammenspiel von Abduktion, Deduktion und Induktion:

- Finde eine Hypothese (Abduktion).
- Leite Voraussagen aus der Hypothese ab (Deduktion).
- Suche nach Fakten, die die Vorannahmen „verifizieren“ (Induktion).
- Werden keine solche Fakten gefunden, zurück zum Anfang.

- Alle Sätze sind Zeichenketten aus Buchstaben eines Alphabets, die nach präzisen Regeln einer Grammatik angeordnet werden.
- Um eine formale Sprache wie das Resolutionskalkül nutzen zu können, müssen wir sowohl deren Syntax als auch deren Semantik kennen.

Lesen Sie laut den Satz: „Die Aussage $A \wedge B$ ist genau dann wahr, wenn die Aussagen A und B wahr sind.“

- Eine Trennung der Sprachebenen ist unerlässlich.
- Die formale Aussage $A \wedge B$ soll dadurch erklärt werden, dass auf einer metasprachlichen Ebene über die Aussage A wie auch über die Aussage B geredet wird.

Wir bezeichnen mit A_i eine atomare Formel. Eine *Formel* wird durch folgenden induktiven Prozess formuliert:

- Alle atomaren Formeln sind Formeln.
- *Konjunktion*: Für alle Formeln F und G ist $(F \wedge G)$ eine Formel.
- *Disjunktion*: Für alle Formeln F und G ist $(F \vee G)$ eine Formel.
- *Negation*: Für jede Formel F ist $\neg F$ eine Formel.

Anmerkung: Durch diese Definition entstehen vollständig geklammerte Formeln.

Eine Formel F , die als Teil einer Formel G auftritt, heißt *Teilformel*.

Beispiel: Die Teilformeln von $F = \neg((A_5 \wedge A_6) \vee \neg A_3)$ sind:

$F, ((A_5 \wedge A_6) \vee \neg A_3), (A_5 \wedge A_6), A_5, A_6, \neg A_3, A_3$

Wir führen abkürzende Schreibweisen ein:

$$(F_1 \rightarrow F_2) \quad \text{statt} \quad (\neg F_1 \vee F_2)$$

$$(F_1 \leftrightarrow F_2) \quad \text{statt} \quad ((F_1 \wedge F_2) \vee (\neg F_1 \wedge \neg F_2))$$

$$\left(\bigvee_{i=1}^n F_i \right) \quad \text{statt} \quad (\dots ((F_1 \vee F_2) \vee F_3) \vee \dots \vee F_n)$$

$$\left(\bigwedge_{i=1}^n F_i \right) \quad \text{statt} \quad (\dots ((F_1 \wedge F_2) \wedge F_3) \wedge \dots \wedge F_n)$$

Bisher sind Formeln lediglich Zeichenreihen:

- Sie haben keinen Inhalt, keine Interpretation.
- Wir müssen erst noch die Bedeutung festlegen.

Die Elemente der Menge $\{0, 1\}$ heißen Wahrheitswerte.

Eine *Belegung* ist eine Funktion $\mathcal{A} : \mathbb{D} \rightarrow \{0, 1\}$, die den atomaren Formeln \mathbb{D} einen Wahrheitswert 0 oder 1 zuweist.

Wir müssen die Funktion \mathcal{A} so erweitern, dass sie auch für Formeln und Teilformeln gilt:

- $\mathcal{A}((F \wedge G)) = \begin{cases} 1, & \text{falls } \mathcal{A}(F) = 1 \text{ und } \mathcal{A}(G) = 1 \\ 0, & \text{sonst} \end{cases}$
- $\mathcal{A}((F \vee G)) = \begin{cases} 1, & \text{falls } \mathcal{A}(F) = 1 \text{ oder } \mathcal{A}(G) = 1 \\ 0, & \text{sonst} \end{cases}$
- $\mathcal{A}(\neg F) = \begin{cases} 1, & \text{falls } \mathcal{A}(F) = 0 \\ 0, & \text{sonst} \end{cases}$

Semantik der Aussagenlogik

Beispiel: Es sei $\mathcal{A}(A) = 1$, $\mathcal{A}(B) = 1$ und $\mathcal{A}(C) = 0$, dann gilt:

$$\begin{aligned}\mathcal{A}(\neg((A \wedge B) \vee C)) &= \begin{cases} 1, & \text{falls } \mathcal{A}(((A \wedge B) \vee C)) = 0 \\ 0, & \text{sonst} \end{cases} \\ &= \begin{cases} 0, & \text{falls } \mathcal{A}(((A \wedge B) \vee C)) = 1 \\ 1, & \text{sonst} \end{cases} \\ &= \begin{cases} 0, & \text{falls } \mathcal{A}((A \wedge B)) = 1 \text{ oder } \mathcal{A}(C) = 1 \\ 1, & \text{sonst} \end{cases} \\ &= \begin{cases} 0, & \text{falls } \mathcal{A}((A \wedge B)) = 1 \text{ (da } \mathcal{A}(C) = 0) \\ 1, & \text{sonst} \end{cases} \\ &= \begin{cases} 0, & \text{falls } \mathcal{A}(A) = 1 \text{ und } \mathcal{A}(B) = 1 \\ 1, & \text{sonst} \end{cases} \\ &= 0\end{aligned}$$

Semantik der Aussagenlogik

Wir können die Wirkung der Operatoren \wedge , \vee , \neg auch durch Verknüpfungstafeln darstellen:

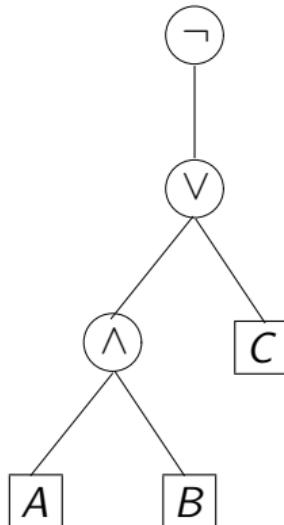
$\mathcal{A}(X)$	$\mathcal{A}(Y)$	$\mathcal{A}(\neg X)$	$\mathcal{A}((X \wedge Y))$	$\mathcal{A}((X \vee Y))$
0	0	1	0	0
0	1	1	0	1
1	0	0	0	1
1	1	0	1	1

Ebenso die Wirkung der Operatoren \rightarrow und \leftrightarrow :

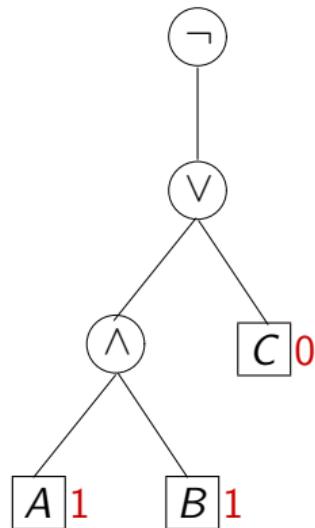
$\mathcal{A}(X)$	$\mathcal{A}(Y)$	$\mathcal{A}((X \rightarrow Y))$	$\mathcal{A}((X \leftrightarrow Y))$
0	0	1	1
0	1	1	0
1	0	0	0
1	1	1	1

Beachte: Aus einer falschen Aussage kann man alles folgern!

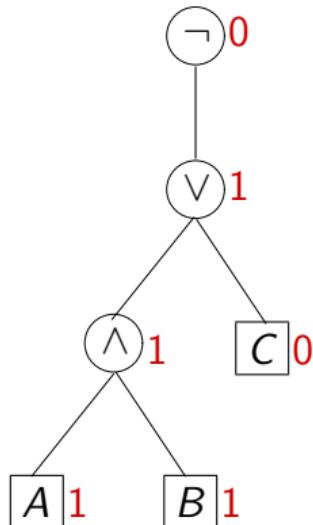
Man kann die Art und Weise, wie Formeln aus einfacheren Teilformeln aufgebaut sind, auch durch eine Baumstruktur darstellen:



Um den Wert der Formel bei einer gegebenen Belegung zu bestimmen, markiere zunächst die Blätter mit den durch die Belegung gegebenen Wahrheitswerten.



Markiere dann von unten nach oben alle Knoten anhand obiger Verknüpfungstafeln.



Definition: Sei F eine Formel und \mathcal{A} eine Belegung.

- Falls \mathcal{A} für alle in F vorkommenden atomaren Formeln definiert ist, heißt \mathcal{A} zu F *passend*.
- Ist \mathcal{A} zu F passend und gilt $\mathcal{A}(F) = 1$, so schreiben wir auch $\mathcal{A} \models F$ und sagen \mathcal{A} ist ein Modell für F oder \mathcal{A} erfüllt F .
- Falls $\mathcal{A}(F) = 0$, so schreiben wir $\mathcal{A} \not\models F$ und sagen \mathcal{A} ist kein Modell für F oder \mathcal{A} erfüllt F nicht.

Eine Formel F heißt

- *erfüllbar*, falls F mindestens ein Modell besitzt.
- *unerfüllbar*, falls es kein Modell für F gibt.
- *allgemeingültig* oder *Tautologie*, falls jede Belegung ein Modell für F ist. Wir schreiben dann: $\models F$
- *falsifizierbar*, falls es eine Belegung gibt, die kein Modell für die Formel ist.

Übung 23. Falls eine Formel F aus n atomaren Formeln aufgebaut ist, wie viele verschiedene Belegungen gibt es für F ?

Übung 24. Wie viele verschiedene Formeln mit den atomaren Formeln A_1, \dots, A_n und verschiedenen Wahrheitswerteverläufen gibt es?

Übung 25. Zeigen Sie folgende wichtige Tautologien.

Modus Ponens $((F \wedge (F \rightarrow G)) \rightarrow G)$

Modus Tollens $((((F \rightarrow G) \wedge \neg G) \rightarrow \neg F)$

Und-Elimination $((F \wedge G) \rightarrow F)$

Oder-Introduktion $(F \rightarrow (F \vee G))$

Resolutionsregel $((((F \rightarrow G) \wedge (\neg F \rightarrow H)) \rightarrow (G \vee H))$

Im Folgenden werden die äußeren Klammern in der Regel weggelassen.

Da wir in wissensbasierten Systemen nicht nur eine, sondern viele Regeln haben, müssen wir obige Begriffe auf Formelmengen erweitern. Sei \mathcal{F} eine Menge von Formeln.

- Dann ist \mathcal{A} ein *Modell* für \mathcal{F} , falls für alle $F \in \mathcal{F}$ gilt $\mathcal{A} \models F$, d.h. \mathcal{A} erfüllt jede Formel in \mathcal{F} .
Insbesondere ist dann \mathcal{A} passend für jede Formel $F \in \mathcal{F}$.
- \mathcal{F} heißt *erfüllbar*, falls \mathcal{F} mindestens ein Modell besitzt, andernfalls heißt \mathcal{F} *unerfüllbar*.

Eine Formel G heißt *Folgerung* der Formeln F_1, \dots, F_k , falls für jede passende Belegung \mathcal{A} für F_1, \dots, F_k und G gilt:

$$\mathcal{A} \text{ ist Modell für } \{F_1, \dots, F_k\} \Rightarrow \mathcal{A} \text{ ist Modell für } G$$

Übung 26. Wir wollen uns ein Haustier anschaffen und machen einige Überlegungen:

- Es soll nur ein Hund (H), eine Katze (K) oder ein Hamster (M) sein.
- Besitzer wertvoller Möbel (W) sollten keine Katze anschaffen, da diese die Möbel zerkratzt.
- Ein Hund erfordert ein freistehendes Haus (F), damit kein Nachbar durch das Bellen gestört wird.

Wir vermuten: Für einen Besitzer wertvoller Möbel ohne freistehendes Haus kommt nur ein Hamster in Frage.

- Wie lauten die Aussagen als aussagenlogische Formeln?
- Wie lautet die Hypothese als aussagenlogische Formel?
- Folgt die Hypothese aus der Formelmenge?

Übung 27. Inspektor Columbo hat drei Personen in Verdacht, die eine Straftat (evtl. gemeinsam) begangen haben. Ihm stehen folgende Informationen zur Verfügung:

- Wenn A schuldig ist und B unschuldig, dann ist C schuldig.
- C arbeitet niemals allein.
- A arbeitet niemals mit C .
- Nur A , B oder C kommen als Täter in Frage.

Inspektor Columbo vermutet, dass B einer der Täter ist. Helfen Sie ihm, indem Sie die Sachverhalte als aussagenlogische Formeln darstellen. Folgt die Hypothese aus der Formelmenge?

Hatte B einen Komplizen? Begründen Sie Ihre Vermutung.

Übung 28. Geben Sie eine Formelmenge \mathcal{F} an, so dass jede echte Teilmenge von \mathcal{F} erfüllbar ist, \mathcal{F} selbst jedoch nicht.

Übung 29. Ist folgende unendliche Formelmenge \mathcal{F} erfüllbar?

$$\mathcal{F} = \{A_1 \vee A_2, \neg A_2 \vee \neg A_3, A_3 \vee A_4, \neg A_4 \vee \neg A_5, \dots\}$$

Übung 30. Zeigen Sie, dass folgende Behauptungen äquivalent sind:

- G ist eine Folgerung von F_1, \dots, F_k
- $((\bigwedge_{i=1}^k F_i) \rightarrow G)$ ist eine Tautologie
- $((\bigwedge_{i=1}^k F_i) \wedge \neg G)$ ist unerfüllbar

Anmerkungen:

- Wir sehen an unseren Beispielen (Haustier, Inspektor Columbo), dass das Testen von Belegungen ineffizient ist.
- Für maschinelle Inferenz wollen wir Techniken nutzen, die allein auf der Syntax der Formeln beruhen.
- Wir suchen eine Folge von syntaktischen Umformungen, die die Hypothese beweisen.

Daher beschäftigen wir uns im Folgenden mit Äquivalenz und Normalformen.

1 Übersicht

2 Geschichte und Anwendungen

3 Wissensrepräsentation

4 Zustandsraumsuche

5 Aussagenlogik

- Grundbegriffe
- Äquivalenz und Normalformen
- Hornformeln
- Resolution

6 Prädikatenlogik

7 Prolog

Syntaktisch unterschiedliche Formeln können dasselbe aussagen:

- $(F \wedge G)$ und $(G \wedge F)$ bedeuten dasselbe, obwohl es syntaktisch zwei verschiedene Objekte sind.
- Auch $\neg(F \vee G)$ und $(\neg F \wedge \neg G)$ sagen dasselbe aus, wie man an den Wahrheitstafeln erkennen kann.

F	G	$\neg(F \vee G)$	$\neg F \wedge \neg G$
0	0	1	1
0	1	0	0
1	0	0	0
1	1	0	0

Im Weiteren: Um eine Hypothese zu beweisen, wollen wir nicht mehr alle Belegungen testen, sondern eine Folge von syntaktischen Umformungen durchführen.

Äquivalenz

Definition: Zwei Formeln F und G heißen (*semantisch*) äquivalent, falls für alle Belegungen \mathcal{A} , die für F und auch für G passend sind, $\mathcal{A}(F) = \mathcal{A}(G)$ gilt. Wir schreiben dann $F \equiv G$.

$$(F \wedge F) \equiv F \quad \text{Idempotenz}$$

$$(F \vee F) \equiv F$$

$$(F \wedge G) \equiv (G \wedge F) \quad \text{Kommutativität}$$

$$(F \vee G) \equiv (G \vee F)$$

$$((F \wedge G) \wedge H) \equiv (F \wedge (G \wedge H)) \quad \text{Assoziativität}$$

$$((F \vee G) \vee H) \equiv (F \vee (G \vee H))$$

$$(F \wedge (F \vee G)) \equiv F \quad \text{Absorption}$$

$$(F \vee (F \wedge G)) \equiv F$$

Äquivalenz

$$\begin{array}{lcl} (F \wedge (G \vee H)) & \equiv & ((F \wedge G) \vee (F \wedge H)) \\ (F \vee (G \wedge H)) & \equiv & ((F \vee G) \wedge (F \vee H)) \end{array} \quad \text{Distributivit\"at}$$

$$\neg\neg F \equiv F \quad \text{Doppelnegation}$$

$$\begin{array}{lcl} \neg(F \wedge G) & \equiv & (\neg F \vee \neg G) \\ \neg(F \vee G) & \equiv & (\neg F \wedge \neg G) \end{array} \quad \text{de-Morgansche-Regeln}$$

$$\begin{array}{lcl} (F \vee G) & \equiv & F, \text{ falls } F \text{ Tautologie} \\ (F \wedge G) & \equiv & G, \text{ falls } F \text{ Tautologie} \end{array} \quad \text{Tautologieregeln}$$

$$\begin{array}{lcl} (F \vee G) & \equiv & G, \text{ falls } F \text{ unerf\"ullbar} \\ (F \wedge G) & \equiv & F, \text{ falls } F \text{ unerf\"ullbar} \end{array} \quad \text{Unerf\"ullbarkeitsregeln}$$

Äquivalenz

Beweis: Alle obigen Äquivalenzen können leicht mittels Wahrheitstafeln nachgeprüft werden.

Beispiel Absorption: $(F \wedge (F \vee G)) \equiv F$

$\mathcal{A}(F)$	$\mathcal{A}(G)$	$\mathcal{A}(F \vee G)$	$\mathcal{A}(F \wedge (F \vee G))$
0	0	0	0
0	1	1	0
1	0	1	1
1	1	1	1

Da die erste und die letzte Spalte übereinstimmen, ist die Äquivalenz der beiden Formeln gezeigt.

Übung 31. Zeigen Sie sowohl durch Wahrheitstafeln als auch durch Anwendung obiger Umformungsregeln, dass

$$(A \vee \neg(B \wedge A)) \wedge (C \vee (D \vee C))$$

äquivalent ist zu $(C \vee D)$.

Übung 32. Zeigen Sie, dass es zu jeder Formel F eine äquivalente Formel G gibt, die nur die Operatoren \neg und \rightarrow enthält.

Übung 33. Zeigen Sie sowohl durch Wahrheitstafeln als auch durch Anwendung obiger Umformungsregeln, dass die beiden folgenden Formeln äquivalent sind.

- $(\neg P \vee Q) \leftrightarrow R$
- $(\neg P \wedge R) \vee (Q \wedge R) \vee (P \wedge \neg Q \wedge \neg R)$

Übung 34. Beweisen Sie die folgenden Verallgemeinerungen der de-Morganschen-Gesetze:

$$\neg \left(\bigvee_{i=1}^n F_i \right) \equiv \left(\bigwedge_{i=1}^n \neg F_i \right) \quad \text{und} \quad \neg \left(\bigwedge_{i=1}^n F_i \right) \equiv \left(\bigvee_{i=1}^n \neg F_i \right)$$

Übung 35. Beweisen Sie die folgenden Verallgemeinerungen der Distributivgesetze:

$$\left(\left(\bigvee_{i=1}^m F_i \right) \wedge \left(\bigvee_{j=1}^n G_j \right) \right) \equiv \left(\bigvee_{i=1}^m \left(\bigvee_{j=1}^n (F_i \wedge G_j) \right) \right)$$

$$\left(\left(\bigwedge_{i=1}^m F_i \right) \vee \left(\bigwedge_{j=1}^n G_j \right) \right) \equiv \left(\bigwedge_{i=1}^m \left(\bigwedge_{j=1}^n (F_i \vee G_j) \right) \right)$$

Im Folgenden: Jede, auch noch so kompliziert aussehende Formel kann in eine gewisse Normalform überführt werden. Obige Umformungsregeln sind dafür ausreichend.

- Ein *Literal* ist eine atomare Formel oder die Negation einer atomaren Formel.
- Eine Formel F ist in *konjunktiver Normalform* (KNF), falls sie eine Konjunktion von Disjunktionen von Literalen ist:

$$F = \left(\bigwedge_{i=1}^n \left(\bigvee_{j=1}^{m_i} L_{i,j} \right) \right)$$

- Eine Formel F ist in *disjunktiver Normalform* (DNF), falls sie eine Disjunktion von Konjunktionen von Literalen ist:

$$F = \left(\bigvee_{i=1}^n \left(\bigwedge_{j=1}^{m_i} L_{i,j} \right) \right)$$

- Die $L_{i,j}$ sind Literale mit $L_{i,j} \in \{A_1, A_2, \dots\} \cup \{\neg A_1, \neg A_2, \dots\}$.

Satz: Für jede Formel F gibt es eine äquivalente Formel in KNF und eine äquivalente Formel in DNF. (Beweis durch Induktion über den Formelaufbau von F , wird hier nicht dargestellt.)

Umformungsmethode zur Herstellung der KNF:

- Ersetze in F jedes Vorkommen von

$$\neg\neg G \text{ durch } G$$

$$\neg(G \wedge H) \text{ durch } (\neg G \vee \neg H)$$

$$\neg(G \vee H) \text{ durch } (\neg G \wedge \neg H)$$

bis keine derartige Teilformel mehr vorkommt.

- Ersetze in F jedes Vorkommen von

$$(F \vee (G \wedge H)) \text{ durch } ((F \vee G) \wedge (F \vee H))$$

$$((F \wedge G) \vee H) \text{ durch } ((F \vee H) \wedge (G \vee H))$$

bis keine derartige Teilformel mehr vorkommt.

Äquivalenz

Oder wir erstellen die Wahrheitstafel zur Formel F und lesen direkt die Teilformeln der disjunktiven Normalform ab:

A	B	C	F
0	0	0	1
0	0	1	0
0	1	0	0
0	1	1	1
1	0	0	1
1	0	1	1
1	1	0	0
1	1	1	0

Die abgelesenen Teilformeln werden mittels \vee verknüpft:

$$(\neg A \wedge \neg B \wedge \neg C) \vee (\neg A \wedge B \wedge C) \vee (A \wedge \neg B \wedge \neg C) \vee (A \wedge \neg B \wedge C)$$

Die Korrektheit dieses Verfahrens ist intuitiv klar.

Äquivalenz

Analog können wir aus der Wahrheitstafel einer Formel F direkt die Teilformeln der konjunktiven Normalform ablesen:

A	B	C	F
0	0	0	1
0	0	1	0
0	1	0	0
0	1	1	1
1	0	0	1
1	0	1	1
1	1	0	0
1	1	1	0

$\rightarrow A \vee B \vee \neg C$

$\rightarrow A \vee \neg B \vee C$

Die abgelesenen Teilformeln werden mittels \wedge verknüpft:

$$(A \vee B \vee \neg C) \wedge (A \vee \neg B \vee C) \wedge (\neg A \vee \neg B \vee C) \wedge (\neg A \vee \neg B \vee \neg C)$$

Dieses Verfahren ist intuitiv vielleicht nicht sofort klar, aber ...

Äquivalenz

... wir können hier die Darstellung in DNF benutzen, um uns die Korrektheit des Verfahrens klar zu machen:

A	B	C	F		
0	0	0	1		
0	0	1	0	$\rightarrow A \vee B \vee \neg C$	$\equiv \neg(\neg A \wedge \neg B \wedge C)$
0	1	0	0	$\rightarrow A \vee \neg B \vee C$	$\equiv \neg(\neg A \wedge B \wedge \neg C)$
0	1	1	1		
1	0	0	1		
1	0	1	1		
1	1	0	0	$\rightarrow \neg A \vee \neg B \vee C$	$\equiv \neg(A \wedge B \wedge \neg C)$
1	1	1	0	$\rightarrow \neg A \vee \neg B \vee \neg C$	$\equiv \neg(A \wedge B \wedge C)$

Wir erstellen die KNF für die negierte Formel und erhalten:

$$\neg((\neg A \wedge \neg B \wedge C) \vee (\neg A \wedge B \wedge \neg C) \vee (A \wedge B \wedge \neg C) \vee (A \wedge B \wedge C))$$

Wenn wir jetzt die Negation nach den de-Morganschen-Regeln in die Klammer ziehen, erhalten wir genau das gewünschte.

Anmerkung: Die so erzeugten KNF- bzw. DNF-Formeln sind nicht notwendigerweise die kürzesten. Z.B. kann man

$$(A \vee B \vee \neg C) \wedge (A \vee \neg B \vee C) \wedge (\neg A \vee \neg B \vee C) \wedge (\neg A \vee \neg B \vee \neg C)$$

vereinfachen zu

$$(A \vee B \vee \neg C) \wedge (A \vee \neg B \vee C) \wedge (\neg A \vee \neg B)$$

Übung 36. Erzeugen Sie mittels Umformung und mittels einer Wahrheitstafel zu der Formel

$$F = ((\neg A \rightarrow B) \wedge ((A \wedge \neg C) \leftrightarrow B))$$

eine äquivalente DNF und KNF.

1 Übersicht

2 Geschichte und Anwendungen

3 Wissensrepräsentation

4 Zustandsraumsuche

5 Aussagenlogik

- Grundbegriffe
- Äquivalenz und Normalformen
- **Hornformeln**
- Resolution

6 Prädikatenlogik

7 Prolog

Definition: Eine Formel F ist eine **Hornformel**, falls F in KNF ist, und jedes Disjunktionsglied in F höchstens ein positives Literal enthält. Wurde benannt nach dem Logiker Alfred Horn.

Beispiel:

$$F = (A \vee \neg B) \wedge (\neg C \vee \neg A \vee D) \wedge (\neg A \vee \neg B) \wedge D \wedge \neg E$$

Hornformeln können anschaulicher geschrieben werden:

$$F = (B \rightarrow A) \wedge (C \wedge A \rightarrow D) \wedge (A \wedge B \rightarrow 0) \wedge (1 \rightarrow D) \wedge (E \rightarrow 0)$$

Dabei steht 0 für eine beliebige unerfüllbare Formel und 1 für eine beliebige Tautologie. Diese Formel ergibt sich aufgrund der Äquivalenz $(X \rightarrow Y) \equiv (\neg X \vee Y)$. Es gilt bspw.

$$\neg A \vee \neg B \vee \neg D \equiv \neg(A \wedge B \wedge D) \equiv \neg(A \wedge B \wedge D) \vee 0 \equiv (A \wedge B \wedge D) \rightarrow 0,$$

$$\neg E \equiv \neg E \vee 0 \equiv E \rightarrow 0 \quad \text{sowie} \quad C \equiv 0 \vee C \equiv \neg 1 \vee C \equiv 1 \rightarrow C.$$

Algorithmischer Test für die Erfüllbarkeit oder Unerfüllbarkeit einer gegebenen Hornformel F :

```
initial: für alle Teilformeln  $1 \rightarrow A_i$  aus  $F$  markiere  $A_i$   
#  $A_i$  muss mit 1 belegt sein, um  $F$  zu erfüllen  
wiederhole  
  ● markiere  $y$ , falls es eine Teilformel  $(A_{i_1} \wedge \dots \wedge A_{i_k}) \rightarrow y$  gibt, bei der  
     $A_{i_1}, \dots, A_{i_k}$  bereits markiert sind  
    #  $y$  muss mit 1 belegt sein, um  $F$  zu erfüllen  
  ● falls es eine Teilformel  $(A_{i_1} \wedge \dots \wedge A_{i_k}) \rightarrow 0$  gibt, bei der  $A_{i_1}, \dots, A_{i_k}$  bereits  
    markiert sind, gib unerfüllbar aus und stoppe  
gib erfüllbar aus und stoppe
```

Die Korrektheit des Algorithmus ergibt sich anhand der obigen Bemerkungen.

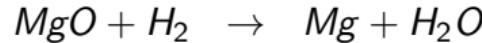
Übung 37. Wenden Sie den Markierungsalgorithmus auf die Formel

$$(\neg A \vee \neg B \vee \neg D) \wedge \neg E \wedge (\neg C \vee A) \wedge C \wedge B \wedge (\neg G \vee D) \wedge G$$

an. Die Wahrheitstafel hätte für diese Formel $2^6 = 64$ Zeilen!

Übung 38. Geben Sie eine Formel an, zu der es keine äquivalente Hornformel gibt und begründen Sie, warum das so ist.

Übung 39. Angenommen, wir könnten die folgenden chemischen Reaktionen durchführen:



Ist es dann möglich, H_2CO_3 aus den Grundstoffen MgO , H_2 , O_2 und C herzustellen?

1 Übersicht

2 Geschichte und Anwendungen

3 Wissensrepräsentation

4 Zustandsraumsuche

5 Aussagenlogik

- Grundbegriffe
- Äquivalenz und Normalformen
- Hornformeln
- Resolution

6 Prädikatenlogik

7 Prolog

Ziel unserer Bemühungen in diesem ganzen Kapitel ist: Wir wollen die *Unerfüllbarkeit* einer gegebenen Formelmenge nachweisen!

Frage: Warum können wir uns auf Unerfüllbarkeitstests beschränken?

Antwort: Um zu testen,

- ob eine Formel F eine Tautologie ist, testen wir einfach $\neg F$ auf Unerfüllbarkeit.
- ob eine Formel G eine Folgerung einer Formelmenge $\mathcal{F} = \{F_1, F_2, \dots, F_k\}$ ist, testen wir die Unerfüllbarkeit von $F_1 \wedge F_2 \wedge \dots \wedge F_k \wedge \neg G$.

- Resolution ist eine einfach anzuwendende syntaktische Umformungsregel.
- Generiere aus zwei Formeln eine dritte Formel, die dann wieder als Eingabe in weitere Resolutionsschritte dienen kann.
- Voraussetzung für die Anwendung der Resolution: Die Formeln müssen in konjunktiver Normalform vorliegen.
- Eine Kollektion rein mechanisch anzuwendender syntaktischer Umformungsregeln nennen wir *Kalkül*.

Ein Kalkül ergänzt die Aussagenlogik oder die Prädikatenlogik um den syntaktischen Begriff des Ableitens, der dem semantischen Folgerungsbegriff entspricht.

- Die Begriffe „wahr“ und „falsch“ kommen in diesem System zunächst gar nicht vor.
- Stattdessen werden Axiome gesetzt, die einfach als Zeichenketten angesehen werden.
- Aus diesen Zeichenketten können weitere ableitbare Zeichenketten aufgrund von bestimmten Schlussregeln (Inferenzregeln) hergeleitet werden.

- In dem formalen System sollen nur Zeichenketten (Sätze) hergeleitet werden können, die bei einer plausiblen Interpretation auch wahr sind. → *Korrektheit*
- Alle Sätze, die als „wahr“ interpretierbar sind, sollen auch hergeleitet werden können. → *Vollständigkeit*

Klassische Aussagenlogik:

- Die Symbole \wedge , \vee und \neg mit den bekannten Interpretationen bilden die Grundlage eines Kalküls (nach George Boole).
- Kalküle sind korrekt als auch vollständig.

Komplexere logische Systeme wie bspw. die Mengenlehre:

- Es ist unmöglich, einen vollständigen Kalkül aufzustellen, der auch korrekt ist,
- siehe Gödelscher Unvollständigkeitssatz.

Die Definition eines Kalküls macht nur dann Sinn, wenn dessen Korrektheit und Vollständigkeit in Bezug zur Aufgabenstellung nachgewiesen werden kann:

- **Aufgabenstellung:** Wir wollen die Unerfüllbarkeit einer gegebenen Formelmenge nachweisen.
- **Korrektheit:** Keine erfüllbare Formelmenge wird durch den Kalkül als vermeintlich unerfüllbar nachgewiesen.
- **Vollständigkeit:** Jede unerfüllbare Formelmenge wird durch den Kalkül als solche nachgewiesen.

Seien A_1, A_2, A_3, \dots aussagenlogische Variablen. Eine endliche Menge $K \subset \{A_1, A_2, A_3, \dots\} \cup \{\neg A_1, \neg A_2, \neg A_3, \dots\}$ heißt eine *Klausel*.

Die Disjunktionsglieder einer konjunktiven Normalform können über Klauseln dargestellt werden.

Beispiel: Die Formel $(A \vee B) \wedge (\neg A \vee C)$ führt zu den Klauseln $\{A, B\}$ und $\{\neg A, C\}$.

Die Menge der Klauseln zu den Disjunktionsgliedern heißt *Klauselmenge der aussagenlogischen Formel*.

Beispiel: Die Formel $(A \vee B) \wedge (\neg A \vee C)$ führt zur Klauselmenge $\{\{A, B\}, \{\neg A, C\}\}$.

Vorteile dieser Darstellung:

- Kommutativität: $(A \vee B) \equiv (B \vee A)$ wird dargestellt durch $\{A, B\}$.
- Assoziativität: $((A \vee B) \vee C) \equiv (A \vee (B \vee C))$ wird dargestellt durch $\{A, B, C\}$.
- Idempotenz: $(A \vee A) \equiv A$ wird dargestellt durch $\{A\}$.

Idee der Resolution

Betrachten wir den Modus Ponens noch einmal:

$$\frac{(A \rightarrow B) \wedge (B \rightarrow C)}{(A \rightarrow C)}$$

Bei der Resolution erhalten wir:

$$\frac{\{\neg A, B\} \wedge \{\neg B, C\}}{\{\neg A, C\}}$$

Zur einfacheren Darstellung sei $\textcircled{1} := \neg A \vee B \equiv A \rightarrow B$,
 $\textcircled{2} := \neg B \vee C \equiv B \rightarrow C$ und
 $\textcircled{3} := \neg A \vee C \equiv A \rightarrow C$.

Wir können die so erhaltene Resolvente $\{\neg A, C\}$ der Klauselmenge $\{\{\neg A, B\}, \{\neg B, C\}\}$ hinzufügen, sodass die erweiterte Klauselmenge äquivalent zur ursprünglichen Klauselmenge ist.

A	B	C	$\textcircled{1}$	$\textcircled{1} \wedge \textcircled{2}$	$\textcircled{2}$	$\textcircled{1} \wedge \textcircled{2} \wedge \textcircled{3}$	$\textcircled{3}$
0	0	0	1	1	1	1	1
0	0	1	1	1	1	1	1
0	1	0	1	0	0	0	1
0	1	1	1	1	1	1	1
1	0	0	0	0	1	0	0
1	0	1	0	0	1	0	1
1	1	0	1	0	0	0	0
1	1	1	1	1	1	1	1

Seien K_1, K_2 und R Klauseln. R heißt *Resolvente* von K_1 und K_2 , falls es ein Literal L gibt mit $L \in K_1$ und $\bar{L} \in K_2$ und R die Form hat:

$$R = (K_1 - \{L\}) \cup (K_2 - \{\bar{L}\})$$

Beispiel:

$$\begin{array}{cc} \{A, \neg B, C\} & \{B, C, D\} \\ \searrow & \swarrow \\ \{A, C, D\} & \end{array}$$

Übung 40. Kann bei der Resolution zweier Hornformeln eine Formel entstehen, die keine Hornformel ist? Begründen Sie Ihre Meinung.

Übung 41. Dürfen die Klauseln $\{A, B, C\}$ und $\{A, \neg B, \neg C\}$ zu $\{A\}$ resolviert werden?

Resolventenmengen

Sei \mathcal{K} eine Klauselmenge. Dann definieren wir:

$$Res(\mathcal{K}) := \mathcal{K} \cup \{R : R \text{ ist Resolvente zweier Klauseln von } \mathcal{K}\}$$

Außerdem setzen wir:

$$Res^0(\mathcal{K}) := \mathcal{K}$$

$$Res^{n+1}(\mathcal{K}) := Res(Res^n(\mathcal{K}))$$

$$Res^*(\mathcal{K}) := \bigcup_{n=1}^{\infty} Res^n(\mathcal{K})$$

Übung 42. Bestimmen Sie für folgende Klauselmenge \mathcal{K} die Mengen $\text{Res}^n(\mathcal{K})$ für $n = 0, 1, 2$.

$$\mathcal{K} = \{\{A, \neg B, C\}, \{B, C\}, \{\neg A, C\}, \{B, \neg C\}, \{\neg C\}\}$$

Übung 43. Geben Sie sämtliche Resolventen an, die aus den Klauseln der folgenden Klauselmenge gewonnen werden können:

$$\{\{A, \neg B, E\}, \{A, B, C\}, \{\neg A, \neg D, E\}, \{A, \neg C\}\}$$

Übung 44. Beweisen Sie, dass es für jede endliche Klauselmenge \mathcal{K} ein $k \geq 0$ gibt mit

$$\text{Res}^k(\mathcal{K}) = \text{Res}^{k+1}(\mathcal{K}) = \dots = \text{Res}^*(\mathcal{K}).$$

Sei F eine Formel in konjunktiver Normalform, dargestellt als Klauselmenge. Ferner sei R eine Resolvente zweier Klauseln K_1 und K_2 aus F . Dann sind F und $F \cup \{R\}$ äquivalent.

Beweis:

- Falls F unerfüllbar ist: Wenn wir F mit einer weiteren Klausel \wedge -verknüpfen, ist auch die neue Formel unerfüllbar.
- Falls F mit einer Variablenbelegung \mathcal{A} erfüllbar ist:
 - Beide Eingangsklauseln K_1 und K_2 sind mit \mathcal{A} erfüllt.
 - Das für die Resolution benutzte Literal L kommt einmal negiert und einmal nicht-negiert in K_1 bzw. K_2 vor, also ist entweder $\mathcal{A}(L) = 0$ oder $\mathcal{A}(\bar{L}) = 0$.
 - Die restliche Klausel beim nicht-erfüllten Auftreten muss erfüllt sein, damit die Klausel und damit auch F erfüllt ist.
 - Auch die Resolvente ist erfüllt, da in jedem Disjunktionsglied nur ein einziges Literal erfüllt sein muss.

Satz: Eine Formel in konjunktiver Normalform mit Klauselmenge \mathcal{K} ist genau dann unerfüllbar, falls mittels Resolution die leere Menge abgeleitet werden kann, also $\emptyset \in \text{Res}^*(\mathcal{K})$.

Wir zeigen zunächst: \mathcal{K} unerfüllbar $\Leftarrow \emptyset \in \text{Res}^*(\mathcal{K})$

Sei also $\emptyset \in \text{Res}^k(\mathcal{K})$ und k minimal.

- In $\text{Res}^{k-1}(\mathcal{K})$ gibt es zwei Klauseln vom Typ $\{A\}$ und $\{\neg A\}$.
- $A \wedge \neg A$ ist unerfüllbar, also ist $\text{Res}^{k-1}(\mathcal{K})$ unerfüllbar.
- Aufgrund des Resolutions-Lemmas gilt:

$$\mathcal{K} \equiv \text{Res}^1(\mathcal{K}) \equiv \text{Res}^2(\mathcal{K}) \equiv \dots \equiv \text{Res}^n(\mathcal{K}) \equiv \dots$$

- Somit ist auch \mathcal{K} unerfüllbar.

Noch zu zeigen: \mathcal{K} unerfüllbar $\Rightarrow \emptyset \in \text{Res}^*(\mathcal{K})$

Beweis durch Induktion über die Anzahl der Variablen n einer Klauselmenge \mathcal{K} .

- Induktionsanfang für $n = 1$:

$\mathcal{K} = \{\{A\}, \{\neg A\}\}$ ist die einzige unerfüllbare Klauselmenge (falls die Variable A genannt wird) und \emptyset entsteht bei der Resolution.

- Induktionsannahme:

Eine fortgesetzte Resolution liefert für jede unerfüllbare Klauselmenge mit n Variablen A_1, A_2, \dots, A_n u.a. die leere Menge.

- Induktionsschritt: Zeige dies für $n + 1$ Variablen.

Induktionsschritt: Sei \mathcal{K} eine unerfüllbare Klauselmenge mit $n + 1$ Variablen A_1, A_2, \dots, A_{n+1} .

- \mathcal{K}_0 entstehe aus \mathcal{K} durch Weglassen von A_{n+1} aus allen Klauseln und Weglassen aller Klauseln mit $\neg A_{n+1}$.
→ belege A_{n+1} mit 0
- \mathcal{K}_1 entstehe aus \mathcal{K} durch Weglassen von $\neg A_{n+1}$ aus allen Klauseln und Weglassen aller Klauseln mit A_{n+1} .
→ belege A_{n+1} mit 1

Gegeben sei eine beliebige Belegung \mathcal{A} der Variablen. Da \mathcal{K} unerfüllbar ist, gilt:

- \mathcal{K}_0 ist unerfüllbar, falls $\mathcal{A}(A_{n+1}) = 0$.
- \mathcal{K}_1 ist unerfüllbar, falls $\mathcal{A}(A_{n+1}) = 1$.

Nach Induktionsannahme kann man also in beiden Fällen mittels Resolution \emptyset erzeugen:

$$\emptyset \in \text{Res}^*(\mathcal{K}_0) \quad \text{und} \quad \emptyset \in \text{Res}^*(\mathcal{K}_1)$$

Fügt man A_{n+1} und $\neg A_{n+1}$ wieder hinzu, so liefert die Resolution für das erweiterte \mathcal{K}_0 eine Menge, in der $\{A_{n+1}\}$ enthalten ist, für das erweiterte \mathcal{K}_1 ist $\{\neg A_{n+1}\}$ enthalten. Also

$$\{A_{n+1}\} \in \text{Res}^*(\mathcal{K}_0) \quad \text{und} \quad \{\neg A_{n+1}\} \in \text{Res}^*(\mathcal{K}_1)$$

Die Resolvente von beiden Mengen ist \emptyset , also $\emptyset \in \text{Res}^*(\mathcal{K})$.

Übung 45. Zeigen Sie mittels Resolution die Unerfüllbarkeit der Klauselmenge

$$\{\{A, B, \neg C\}, \{\neg A\}, \{A, B, C\}, \{A, \neg B\}\},$$

also der Formel

$$(A \vee B \vee \neg C) \wedge (\neg A) \wedge (A \vee B \vee C) \wedge (A \vee \neg B).$$

Übung 46. Leiten Sie die Hypothese „für einen Besitzer wertvoller Möbel ohne freistehendes Haus kommt nur ein Hamster in Frage“ aus Übung 26 mittels Resolution her.

Übung 47. Diätplan: „Das ist ja unmöglich, mit dieser Baukasten-Diät“, seufzt Robert.

- Wenn ich einen Apfel esse, muss ich auch einen Salzhering nehmen. Wegen der Mineralien.
- Esse ich eine Banane, muss ich eine Scheibe Knäckebrot hinterher essen - oder ich lasse den Salzhering liegen.
- Aber wenn ich ein Tortenstück esse, darf ich kein Knäckebrot nehmen - zu viele Kohlehydrate.
- Esse ich einen Apfel, soll ich auch ein Tortenstück nehmen.
- Wenn ich keinen Milchreis esse, soll ich eine Banane nehmen.
- Ich esse auf jeden Fall einen Apfel, aber keinen Milchreis - den vertrage ich nicht.

„Pack den Diätplan weg“, sagt Sabine, „er ist für dich wirklich unmöglich!“.

Frage: Hat Sabine Recht?

Wir können keine Aussagen über ganze Klassen von Objekten machen, so dass Schlussfolgerungen für individuelle Objekte möglich sind.

Beispiel: Gegeben seien folgende Fakten bzw. Regeln:

- Martin ist Informatiker.
- Peter ist Informatiker.
- Jeder Informatiker kann programmieren.

Folgerungen:

- Martin kann programmieren.
- Peter kann programmieren.

1 Übersicht

2 Geschichte und Anwendungen

3 Wissensrepräsentation

4 Zustandsraumsuche

5 Aussagenlogik

6 Prädikatenlogik

7 Prolog

1 Übersicht

2 Geschichte und Anwendungen

3 Wissensrepräsentation

4 Zustandsraumsuche

5 Aussagenlogik

6 Prädikatenlogik

- Grundbegriffe
- Normalformen
- Unentscheidbarkeit
- Herbrand-Theorie
- Resolution

7 Prolog

Die Prädikatenlogik ist eine Erweiterung der Aussagenlogik. Hinzu kommen der Allquantor \forall , der Existenzquantor \exists sowie Funktions- und Prädikatsymbole.

Analog zur Aussagenlogik kann auch für die Prädikatenlogik deren Syntax und Semantik mathematisch präzise definiert werden.

Syntax der Prädikatenlogik:

- Eine *Variable* hat die Form x_i mit $i = 1, 2, 3, \dots$
- Ein *Prädikatsymbol* hat die Form P_i^k mit $i = 1, 2, 3, \dots$ und $k = 0, 1, 2, \dots$
- Ein *Funktionssymbol* hat die Form f_i^k mit $i = 1, 2, 3, \dots$ und $k = 0, 1, 2, \dots$
- Man nennt i den *Unterscheidungsindex* und k die *Stellenzahl* oder auch *Stelligkeit*.

Der Begriff *Term* wird durch einen induktiven Prozess definiert:

- Jede Variable ist ein Term.
- Falls f ein Funktionssymbol ist mit Stellenzahl k , und falls t_1, \dots, t_k Terme sind, so ist auch $f(t_1, \dots, t_k)$ ein Term.

Auch Funktionssymbole der Stellenzahl 0 sollen eingeschlossen sein, in einem solchen Fall fallen die Klammern weg.

Nullstellige Funktionssymbole heißen auch *Konstanten*.

Auch die Formeln der Prädikatenlogik können wir induktiv definieren:

- Falls P ein Prädikatsymbol der Stelligkeit k ist, und falls t_1, \dots, t_k Terme sind, dann ist $P(t_1, \dots, t_k)$ eine Formel.
Solche Formeln nennen wir auch *atomare Formeln*.
- Für jede Formel F ist auch $\neg F$ eine Formel.
- Für alle Formeln F und G sind auch $(F \wedge G)$ und $(F \vee G)$ Formeln.
- Falls x eine Variable ist und F eine Formel, so sind auch $\exists x F$ und $\forall x F$ Formeln.

Falls F eine Formel ist und F als Teil einer Formel G auftritt, so heißt F *Teilformel* von G .

Alle Vorkommen von Variablen in einer Formel werden in *freie* und *gebundene* Vorkommen unterteilt:

- Ein Vorkommen der Variablen x in der Formel F heißt *gebunden*, falls x in einer Teilformel der Form $\exists x G$ oder $\forall x G$ vorkommt,
- andernfalls heißt dieses Vorkommen von x *frei*.

→ Dieselbe Variable kann also in einer Formel an verschiedenen Stellen sowohl frei als auch gebunden vorkommen.

Eine Formel ohne Vorkommen einer freien Variablen heißt *geschlossen* oder auch eine *Aussage*.

Beispiel:

$$F = (\exists x_1 \ P_5^2(x_1, f_2^1(x_2)) \vee \neg \forall x_2 \ P_4^2(x_2, f_7^2(f_4^0, f_5^1(x_3))))$$

ist eine Formel. Sämtliche Teilformeln von F sind:

- F
- $\neg \forall x_2 \ P_4^2(x_2, f_7^2(f_4^0, f_5^1(x_3)))$
- $\exists x_1 \ P_5^2(x_1, f_2^1(x_2))$
- $\forall x_2 \ P_4^2(x_2, f_7^2(f_4^0, f_5^1(x_3)))$
- $P_5^2(x_1, f_2^1(x_2))$
- $P_4^2(x_2, f_7^2(f_4^0, f_5^1(x_3)))$

Weiterhin gilt:

- Alle Vorkommen von x_1 in F sind gebunden.
- Erstes Vorkommen von x_2 ist frei, zweites ist gebunden.
- x_3 kommt in F frei vor.

→ Die Formel F ist nicht geschlossen bzw. keine Aussage.

Alle in F vorkommenden Terme sind:

- x_1
- x_2
- $f_2^1(x_2)$
- $f_7^2(f_4^0, f_5^1(x_3))$
- f_4^0
- $f_5^1(x_3))$
- x_3

Der Term f_4^0 stellt eine Konstante dar.

Wir vereinbaren wieder die vereinfachenden Schreibweisen wie in der Aussagenlogik. Außerdem legen wir fest:

- u, v, w, x, y, z stehen für Variablen.
- a, b, c stehen für Konstanten.
- f, g, h stehen für Funktionssymbole, die Stelligkeit geht immer aus dem Kontext hervor.
- P, Q, R stehen für Prädikatsymbole, auch hier geht die Stelligkeit aus dem Kontext hervor.

Übung 48. Geben Sie sämtliche Teilformeln und Terme an, die in der folgenden Formel enthalten sind:

$$F = ((Q(x) \vee \exists x \forall y (P(f(x), z) \wedge Q(a))) \vee \forall z R(x, z, g(x)))$$

Welche Teilformeln sind Aussagen? Bestimmen Sie für jedes Vorkommen einer Variablen, ob die Variable frei oder gebunden ist.

Semantik der Prädikatenlogik: Eine *Struktur* ist ein Paar $\mathcal{A} = (U_{\mathcal{A}}, I_{\mathcal{A}})$, wobei $U_{\mathcal{A}}$ eine beliebige aber nicht leere Menge ist, die die *Grundmenge* von \mathcal{A} , der *Individuenbereich* oder auch *Universum* genannt wird.

Ferner ist $I_{\mathcal{A}}$ eine Abbildung, die

- jedem im Definitionsbereich von $I_{\mathcal{A}}$ liegenden k -stelligen Prädikatsymbol P ein k -stelliges Prädikat über $U_{\mathcal{A}}$ zuordnet,
- jedem im Definitionsbereich von $I_{\mathcal{A}}$ liegenden k -stelligen Funktionssymbol f eine k -stellige Funktion auf $U_{\mathcal{A}}$ zuordnet,
- jeder Variablen x (sofern $I_{\mathcal{A}}$ auf x definiert ist) ein Element der Grundmenge $U_{\mathcal{A}}$ zuordnet.

Wir schreiben abkürzend statt $I_{\mathcal{A}}(P)$ einfach $P^{\mathcal{A}}$, statt $I_{\mathcal{A}}(f)$ einfach $f^{\mathcal{A}}$ und statt $I_{\mathcal{A}}(x)$ einfach $x^{\mathcal{A}}$.

Sei F eine Formel und $\mathcal{A} = (U_{\mathcal{A}}, I_{\mathcal{A}})$ eine Struktur. \mathcal{A} heißt zu F *passend*, falls $I_{\mathcal{A}}$ für alle in F vorkommenden Prädikatsymbole, Funktionssymbole und freien Variablen definiert ist.

Beispiel: $F = \forall x \ P(x, f(x)) \wedge Q(g(a, z))$ ist eine Formel. Eine zu F passende Struktur ist bspw. $\mathcal{A} = (U_{\mathcal{A}}, I_{\mathcal{A}})$ mit

$$\begin{aligned}U_{\mathcal{A}} &= \{0, 1, 2, 3, \dots\} = \mathbb{N} \\I_{\mathcal{A}}(P) &= P^{\mathcal{A}} = \{(m, n) \mid m, n \in U_{\mathcal{A}} \text{ und } m < n\} \\I_{\mathcal{A}}(Q) &= Q^{\mathcal{A}} = \{n \in U_{\mathcal{A}} \mid n \text{ ist Primzahl}\} \\I_{\mathcal{A}}(f) &= f^{\mathcal{A}} \text{ mit } f^{\mathcal{A}}(n) := n + 1 \\I_{\mathcal{A}}(g) &= g^{\mathcal{A}} \text{ mit } g^{\mathcal{A}}(m, n) := m + n \\I_{\mathcal{A}}(a) &= a^{\mathcal{A}} = 2 \\I_{\mathcal{A}}(z) &= z^{\mathcal{A}} = 3\end{aligned}$$

Mit anderen Worten: Wir haben Interpretationen der Prädikate und Funktionen angegeben und eine Belegung der freien Variablen und der Konstanten festgelegt. Wir wissen jetzt,

- was die Prädikate P und Q bedeuten,
- wie die Funktionen f und g definiert sind,
- das die Konstante a den Wert 2 hat,
- das die Variable x den Wert 3 hat
- und auf welcher Grundmenge das alles definiert ist.

Intuitiv:

- Jede natürliche Zahl ist kleiner als ihr Nachfolger und die Summe von 2 und 3 ist eine Primzahl.

→ In dieser Struktur gilt die Formel F .

- F ist nicht notwendigerweise in jeder Struktur gültig!

Wir wollen den Begriff *gültig* nun formal definieren.

Sei F eine Formel und \mathcal{A} eine zu F passende Struktur. Für jeden Term t aus Variablen und Funktionssymbolen von F definieren wir induktiv den *Wert* von t in der Struktur \mathcal{A} , den wir mit $\mathcal{A}(t)$ bezeichnen:

- Falls t eine Variable ist (also $t = x$), so ist $\mathcal{A}(t) = x^{\mathcal{A}}$.
- Falls t die Form $t = f(t_1, \dots, t_k)$ hat, wobei t_1, \dots, t_k Terme und f ein k -stelliges Funktionssymbol ist, so ist

$$\mathcal{A}(t) = f^{\mathcal{A}}(\mathcal{A}(t_1), \dots, \mathcal{A}(t_k)).$$

Dieser Fall schließt auch die Möglichkeit ein, dass f nullstellig ist, also t die Form $t = a$ hat. Dann ist $\mathcal{A}(t) = a^{\mathcal{A}}$.

Analog definieren wir induktiv den (Wahrheits-) *Wert* der Formel F unter der Struktur \mathcal{A} , wobei wir ebenfalls die Bezeichnung $\mathcal{A}(F)$ verwenden.

- Falls F die Form $F = P(t_1, \dots, t_k)$ hat mit den Termen t_1, \dots, t_k und einem k -stelligen Prädikatsymbol P , so gilt:

$$\mathcal{A}(F) = \begin{cases} 1, & \text{falls } (\mathcal{A}(t_1), \dots, \mathcal{A}(t_k)) \in P^{\mathcal{A}} \\ 0, & \text{sonst} \end{cases}$$

- Falls F die Form $F = \neg G$ hat, so gilt:

$$\mathcal{A}(F) = \begin{cases} 1, & \text{falls } \mathcal{A}(G) = 0 \\ 0, & \text{sonst} \end{cases}$$

- Falls F die Form $F = (G \wedge H)$ hat, so gilt:

$$\mathcal{A}(F) = \begin{cases} 1, & \text{falls } \mathcal{A}(G) = 1 \text{ und } \mathcal{A}(H) = 1 \\ 0, & \text{sonst} \end{cases}$$

- Falls F die Form $F = (G \vee H)$ hat, so gilt:

$$\mathcal{A}(F) = \begin{cases} 1, & \text{falls } \mathcal{A}(G) = 1 \text{ oder } \mathcal{A}(H) = 1 \\ 0, & \text{sonst} \end{cases}$$

- Falls F die Form $F = \forall x \ G$ hat, so gilt:

$$\mathcal{A}(F) = \begin{cases} 1, & \text{falls f\"ur alle } d \in U_{\mathcal{A}} \text{ gilt: } \mathcal{A}_{[x/d]}(G) = 1 \\ 0, & \text{sonst} \end{cases}$$

- Falls F die Form $F = \exists x \ G$ hat, so gilt:

$$\mathcal{A}(F) = \begin{cases} 1, & \text{falls es ein } d \in U_{\mathcal{A}} \text{ gibt mit: } \mathcal{A}_{[x/d]}(G) = 1 \\ 0, & \text{sonst} \end{cases}$$

$\mathcal{A}_{[x/d]}$ bezeichne die Struktur \mathcal{A}' , die mit \mathcal{A} identisch ist, bis auf die Definition von $x^{\mathcal{A}'}$: Es sei $x^{\mathcal{A}'} = d$, wobei $d \in U_{\mathcal{A}} = U_{\mathcal{A}'}$.

Man k\"onnte auch sagen: x wird mit dem Wert d belegt.

Analog zur Aussagenlogik definieren wir:

- Falls $\mathcal{A}(F) = 1$ für eine Formel F und einer zu F passenden Struktur \mathcal{A} gilt, so schreiben wir $\mathcal{A} \models F$ und sagen: F gilt in \mathcal{A} oder auch \mathcal{A} ist **Modell** für F .
- Falls jede zu F passende Struktur ein Modell für F ist, so schreiben wir $\models F$ und sagen F ist (allgemein-)**gültig**.
- Falls es ein Modell für die Formel F gibt, so heißt F **erfüllbar**, andernfalls **unerfüllbar**.
- Weitere Begriffe wie **Folgerung** und **Äquivalenz** können aus der Aussagenlogik übertragen werden.

Analog zum aussagenlogischen Fall lässt sich zeigen, dass für jede Formel F gilt:

F ist genau dann (allgemein-)gültig, wenn $\neg F$ unerfüllbar ist.

Wir schieben für einen Augenblick die präzise mathematische Definition beiseite, damit vielleicht klarer wird, was wir eigentlich gerade tun.

Ersetzt man in einer Aussage A eine Konstante durch eine Variable x , so entsteht die *Aussageform* $A(x)$, auch *Prädikat* $A(x)$ genannt.

- Krefeld liegt am Rhein $\rightarrow x$ liegt am Rhein
- 5 ist eine natürliche Zahl $\rightarrow y$ ist eine natürliche Zahl

Häufig hat man weitere Variablen und zusätzlich auch Terme, die über Variablen gebildet werden, z.B.

- 7 ist kleiner als 12 $\rightarrow x$ ist kleiner als y
→ Wir erhalten ein Prädikat der Form $A(x, y)$.
- 7 plus 3 ist kleiner als 12 $\rightarrow x + y$ ist kleiner als z
→ Wir erhalten ein Prädikat der Form $A(t(x, y), z)$.

- Eine Aussageform/ein Prädikat hat im Allgemeinen keinen bestimmten Wahrheitswert.
- Erst wenn die Variable durch einen konkreten Wert ersetzt wird, entsteht eine Aussage, die einen Wahrheitswert hat.

Aus der Aussagenlogik wird durch die Aussageformen die *Prädikatenlogik*. Im Folgenden einige Beispiele dazu.

Aussageform: $A(x) := x^2 > 30$

- $A(x)$ wird für $x = 6$ zur wahren Aussage.
- Für $x = 5$ ist $A(x)$ falsch.
- $\neg A(x)$ lautet $x^2 \leq 30$.

Aussageform: $A(x) := x$ ist eine Ampelfarbe

- Für $x \in \{\text{rot, gelb, grün}\}$ wird $A(x)$ wahr.
- Für $x = \text{blau}$ wird $A(x)$ zu einer falschen Aussage.

Der **Allquantor** \forall steht für den Text „für alle“.

- $\forall x \in E : A(x)$ ist die Aussage, die in Textform lautet:
„Für alle Elemente x von E gilt: Die Aussageform $A(x)$ wird eine wahre Aussage.“
Oder anders formuliert: $A(x)$ wird für jedes $x \in E$ wahr.

Beispiele für wahre Aussagen:

- $\forall x \in \{\text{rot, gelb, grün}\} : x \text{ ist eine Ampelfarbe}$
- $\forall x \in \{-3, -2, -1, 0, 1, 2, 3\} : (x^2 = 4 \iff x = 2 \vee x = -2)$

Der *Existenzquantor* \exists steht für den Text „es existiert“.

- $\exists x \in E : A(x)$ ist die Aussage, die in Textform lautet:

„Es existiert (mindestens) ein Element x von E , so dass $A(x)$ für dieses Element x wahr wird.“

Oder anders formuliert: $A(x)$ wird für (mindestens) ein $x \in E$ wahr.

Beispiele für wahre Aussagen:

- $\exists x \in \{\text{blau, gelb, grün}\} : x$ ist eine Ampelfarbe
- $\exists x \in \{1, 2, 3\} : x^2 = 4$

Übung 49. Das Prädikat $mutter(a, b)$ bedeute, dass a Mutter von b ist. Beschreiben Sie umgangssprachlich die folgenden Formeln:

- $\forall y \exists x \, mutter(x, y)$
- $\exists x \forall y \, mutter(x, y)$

Übung 50. Drücken Sie folgende Sachverhalte mittels Prädikaten aus:

- Alle Studenten sind arm.
- Alle grünen Pilze sind giftig.
- Es gibt einen armen Studenten.
- Wer schneller als Anna ist, ist auch schneller als Klaus.
- Niemand ist schneller als Harald.
- Claudia ist die schnellste.

Übung 51.

Formulieren Sie das Kannibalen und Missionare-Problem mittels Prädikatenlogik:

- 3 Missionare und 3 Kannibalen wollen einen Fluss überqueren.
- Es steht nur ein Ruderboot für die Überfahrt zur Verfügung.
- Das Boot kann maximal 2 Personen aufnehmen.
- Es dürfen nie mehr Kannibalen als Missionare an einem Ort sein, sonst gibt es ein großes Fressen.

Wie muss die Formulierung geändert werden, wenn zwar alle Missionare rudern können, aber nur einer der Kannibalen?

1 Übersicht

2 Geschichte und Anwendungen

3 Wissensrepräsentation

4 Zustandsraumsuche

5 Aussagenlogik

6 Prädikatenlogik

- Grundbegriffe
- Normalformen
- Unentscheidbarkeit
- Herbrand-Theorie
- Resolution

7 Prolog

Zwei prädikatenlogische Formeln F und G heißen *äquivalent*, falls für alle sowohl zu F als auch zu G passenden Strukturen \mathcal{A} gilt: $\mathcal{A}(F) = \mathcal{A}(G)$

Alle in der Aussagenlogik gezeigten Äquivalenzen gelten auch in der Prädikatenlogik:

- Idempotenz
- Kommutativität
- Assoziativität
- Absorption
- Distributivität
- Doppelnegation
- deMorgansche Regeln
- usw.

Um auch prädikatenlogische Formeln in Normalformen umformen zu können, benötigen wir noch Äquivalenzen, die Quantoren mit einbeziehen.

Seien F und G beliebige Formeln. Dann gilt:

1.a $\neg \forall x F \equiv \exists x \neg F$

Beispiel: „**Nicht alle** Fußballspiele der 1. Bundesliga am vergangenen Spieltag endeten unentschieden.“

Ist äquivalent zu: „**Es gab** am vergangenen Spieltag der 1. Bundesliga (mindestens) ein Fußballspiel, das **nicht** unentschieden endete.“

Beispiel: „**Nicht alle** Außerirdischen haben grüne Haut.“

Ist äquivalent zu: „**Es gibt** Außerirdische, die **keine** grüne Haut haben.“

1.b $\neg \exists x F \equiv \forall x \neg F$

Beispiel: „**Es gab kein** Fußballspiel der 1. Bundesliga, das am vergangenen Spieltag unentschieden endete.“

Ist äquivalent zu: „**Alle** Fußballspiele der 1. Bundesliga des vergangenen Spieltags endeten **nicht** unentschieden.“

2. Falls x in G nicht frei vorkommt, gilt:

$$(\forall x \ F \wedge G) \equiv \forall x \ (F \wedge G)$$

$$(\forall x \ F \vee G) \equiv \forall x \ (F \vee G)$$

$$(\exists x \ F \wedge G) \equiv \exists x \ (F \wedge G)$$

$$(\exists x \ F \vee G) \equiv \exists x \ (F \vee G)$$

3. $(\forall x \ F \wedge \forall x \ G) \equiv \forall x \ (F \wedge G)$

$$(\exists x \ F \vee \exists x \ G) \equiv \exists x \ (F \vee G)$$

4. $\forall x \forall y \ F \equiv \forall y \forall x \ F$

$$\exists x \exists y \ F \equiv \exists y \exists x \ F$$

Übung 52. Formulieren Sie Beispiele für obige Aussagen 2 bis 4.

Übung 53. Machen Sie sich klar, dass obige zweite Aussage auch einen Fall wie $G = \forall y \ \exists z \ Q(y, z)$ einschließt und welche Folgen das hat.

Exemplarisch beweisen wir: $(\forall x F \wedge G) \equiv \forall x (F \wedge G)$

$$\mathcal{A}(\forall x F \wedge G) = 1$$

$$\iff \mathcal{A}(\forall x F) = 1 \text{ und } \mathcal{A}(G) = 1$$

\iff Für alle $d \in U_{\mathcal{A}}$ gilt $\mathcal{A}_{[x/d]}(F) = 1$ und $\mathcal{A}_{[x/d]}(G) = 1$, denn
weil x in G nicht frei vorkommt, gilt $\mathcal{A}(G) = \mathcal{A}_{[x/d]}(G)$.

$$\iff \text{Für alle } d \in U_{\mathcal{A}} \text{ gilt: } \mathcal{A}_{[x/d]}((F \wedge G)) = 1$$

$$\iff \mathcal{A}(\forall x (F \wedge G)) = 1$$

Übung 54. Zeigen Sie, dass folgende Formelpaare *nicht* äquivalent sind, indem Sie Gegenbeispiele angeben:

$$(\forall x F \vee \forall x G) \not\equiv \forall x (F \vee G)$$

$$(\exists x F \wedge \exists x G) \not\equiv \exists x (F \wedge G)$$

Übung 55. Bei verschiedenen Quantoren ist die Reihenfolge extrem wichtig. Es gilt folgende *Nicht-Äquivalenz*:

$$\forall x \exists y F \not\equiv \exists y \forall x F$$

Formulieren Sie ein Beispiel, das den Sachverhalt deutlich macht.

Übung 56. Zeigen Sie, dass $\forall x \exists y P(x, y)$ eine Folgerung von $\exists y \forall x P(x, y)$ ist, aber nicht umgekehrt.

Durch obige Äquivalenzumformungen können wir die in einer Formel evtl. vorhandenen Quantoren an den Anfang der Formel verschieben:

$$\begin{aligned} & (\neg(\exists x P(x, y) \vee \forall z Q(z)) \wedge \exists w P(f(a, w))) \\ \equiv & ((\neg\exists x P(x, y) \wedge \neg\forall z Q(z)) \wedge \exists w P(f(a, w))) \text{ deMorgan} \\ \equiv & ((\forall x \neg P(x, y) \wedge \exists z \neg Q(z)) \wedge \exists w P(f(a, w))) \text{ wegen 1.} \\ \equiv & (\exists w P(f(a, w)) \wedge (\forall x \neg P(x, y) \wedge \exists z \neg Q(z))) \text{ kommutativ} \\ \equiv & \exists w (P(f(a, w)) \wedge \forall x (\neg P(x, y) \wedge \exists z \neg Q(z))) \text{ wegen 2.} \\ \equiv & \exists w (\forall x (\exists z \neg Q(z) \wedge \neg P(x, y)) \wedge P(f(a, w))) \text{ kommutativ} \\ \equiv & \exists w (\forall x \exists z (\neg Q(z) \wedge \neg P(x, y)) \wedge P(f(a, w))) \text{ wegen 2.} \\ \equiv & \exists w \forall x \exists z ((\neg Q(z) \wedge \neg P(x, y)) \wedge P(f(a, w))) \text{ wegen 2.} \end{aligned}$$

Punkt 2 des obigen Satzes kann nicht immer angewendet werden:

$$\forall x \ P(x, y) \wedge Q(x) \not\equiv \forall x \ (P(x, y) \wedge Q(x))$$

Um die Regel 2 dennoch anwenden zu können, benennen wir zunächst die freie Variable x um:

$$\begin{aligned} \forall x \ P(x, y) \wedge Q(x) &\equiv \forall x \ P(x, y) \wedge Q(z) \\ &\equiv \forall x \ (P(x, y) \wedge Q(z)) \end{aligned}$$

Ein solches Umbenennen von Variablen heißt *Substitution*. Sei F eine Formel, x eine Variable und t ein Term.

Dann bezeichnet $F[x/t]$ diejenige Formel, die man aus F erhält, indem jedes freie Vorkommen der Variablen x in F durch den Term t ersetzt wird.

Anmerkung: Wir müssen zwischen $\mathcal{A}_{[x/d]}$ und $F[x/t]$ deutlich unterscheiden. Im ersten Fall erhalten wir eine neue Struktur, bei der x den Wert d erhält (Semantik), im zweiten Fall erhalten wir eine neue Formel, bei der x durch t ersetzt ist (Syntax).

Lemma: (gebundene Umbenennung)

Falls die Variable y nicht in der Formel G vorkommt, gilt:

$$\forall x \ G \equiv \forall y \ G[x/y]$$

$$\exists x \ G \equiv \exists y \ G[x/y]$$

Beispiel: Aus

$$\forall x \ P(x) \wedge Q(x, y)$$

wird durch gebundene Umbenennung die äquivalente Formel

$$\forall z \ P(z) \wedge Q(x, y).$$

Durch systematisches Ausführen von gebundenen Umbenennungen, wobei immer neue, noch nicht vorkommende Variablen verwendet werden, kann man das folgende Lemma zeigen.

Lemma: Zu jeder Formel F gibt es eine äquivalente Formel G in bereinigter Form.

Eine Formel heißt *bereinigt*, sofern es keine Variable gibt, die in der Formel sowohl frei als auch gebunden vorkommt, und sofern hinter allen vorkommenden Quantoren verschiedene Variablen stehen.

Beispiel:

$$\begin{aligned} & \forall x \exists y P(x, f(y)) \wedge \forall y (Q(x, y) \vee R(x)) \\ & \equiv \forall u \exists y P(u, f(y)) \wedge \forall y (Q(x, y) \vee R(x)) \\ & \equiv \forall u \exists v P(u, f(v)) \wedge \forall y (Q(x, y) \vee R(x)) \end{aligned}$$

Freie Variablen: x

Gebundene Variablen: u, v, y

Eine Formel heißt *pränex* oder in *Pränexform*, falls sie die Bauart

$$Q_1 y_1 \ Q_2 y_2 \ \dots \ Q_n y_n \ F$$

hat, wobei $Q_i \in \{\exists, \forall\}$, $n \geq 0$, und die y_i Variablen sind. Ferner kommt kein Quantor in F vor.

Satz: Für jede Formel F gibt es eine äquivalente und bereinigte Formel G in Pränexform.

Beispiel:

$$\begin{aligned} & \forall x \exists y [P(x, g(y, f(x))) \vee \neg Q(z)] \vee \neg \forall x R(x, y) \\ & \equiv \forall x \exists y [P(x, g(y, f(x))) \vee \neg Q(z)] \vee \exists x \neg R(x, y) \\ & \equiv \forall x \exists y [P(x, g(y, f(x))) \vee \neg Q(z)] \vee \exists v \neg R(v, y) \\ & \equiv \forall x \exists u [P(x, g(u, f(x))) \vee \neg Q(z)] \vee \exists v \neg R(v, y) \\ & \equiv \forall x \exists u \exists v [P(x, g(u, f(x))) \vee \neg Q(z) \vee \neg R(v, y)] \end{aligned}$$

Beweis: Induktion über Formelaufbau.

Wenn F eine atomare Formel ist, so liegt F bereits in Pränexform vor. Für den Induktionsschluss unterscheiden wir verschiedene Fälle.

- F hat die Form $\neg F_1$ und $G_1 = Q_1 y_1 \ Q_2 y_2 \ \dots \ Q_n y_n \ G'$ sei die zu F_1 äquivalente Formel, die nach Induktionsvoraussetzung existiert. Dann gilt

$$F \equiv \overline{Q_1} y_1 \ \overline{Q_2} y_2 \ \dots \ \overline{Q_n} y_n \ \neg G'$$

mit $\overline{Q_i} = \exists$, falls $Q_i = \forall$, und $\overline{Q_i} = \forall$, falls $Q_i = \exists$.

- F hat die Form $(F_1 \circ F_2)$ mit $\circ \in \{\wedge, \vee\}$. Seien G_1 und G_2 die zu F_1 und F_2 äquivalenten Formeln in Pränexform. Durch gebundenes Umbenennen erhalten wir

$$G_1 = Q_1 y_1 \ Q_2 y_2 \ \dots \ Q_n y_n \ G'_1 \quad \text{und} \quad G_2 = Q'_1 z_1 \ Q'_2 z_2 \ \dots \ Q'_m z_m \ G'_2$$

Formeln, deren gebundene Variablen disjunkt sind mit $Q_i, Q'_j \in \{\exists, \forall\}$. Dann gilt:

$$F \equiv Q_1 y_1 \ Q_2 y_2 \ \dots \ Q_n y_n \ Q'_1 z_1 \ Q'_2 z_2 \ \dots \ Q'_m z_m (G'_1 \circ G'_2)$$

- F hat die Form $Qx \ F_1$ mit $Q \in \{\exists, \forall\}$ und $F_1 = Q_1 y_1 \ Q_2 y_2 \ \dots \ Q_n y_n \ F'_1$ und x ist disjunkt zu y_1, \dots, y_n . Dann gilt:

$$F \equiv Qx \ Q_1 y_1 \ Q_2 y_2 \ \dots \ Q_n y_n \ F'_1$$

Für die prädikatenlogische Variante der Resolution müssen wir die Formeln noch weiter vereinfachen: Zunächst werden freie Variablen durch Einführen von Existenzquantoren gebunden: $\forall x P(x, y)$ ist erfüllbarkeitsäquivalent zu $\forall x \exists y P(x, y)$.

Schließlich werden Existenzquantoren durch *Skolemisierung* eliminiert.

- Tritt die Form $\exists x$ nicht im Geltungsbereich eines Allquantors auf, wird $\exists x$ einfach weggelassen und alle Auftreten von x werden durch eine neue Konstante c ersetzt.

Beispiel: Aus $\exists x P(x)$ wird $P(c)$.

Beispiel: Aus $\exists x \exists z \forall y P(y, x, z)$ wird $\forall y P(y, c_1, c_2)$.

- Tritt dagegen $\exists x$ im Geltungsbereich der allquantifizierten Variablen y_1, \dots, y_k auf, so werden alle Auftreten von x durch den Term $f(y_1, \dots, y_k)$ ersetzt, wobei f ein neues Funktionssymbol sein muss.

Beispiel: Aus $\forall y \exists x P(x, y)$ wird $\forall y P(f(y), y)$.

Beispiel: Aus $\exists x \forall y \exists z P(y, x, z)$ wird $\forall y P(y, c, f(y))$.

Die vollständige Skolemisierung einer Formel F entfernt alle Existenzquantoren aus F und liefert eine Formel F' , die erfüllbarkeitsäquivalent zu F ist, d.h. F ist genau dann erfüllbar, wenn F' erfüllbar ist.

Übung 57. Geben Sie die Skolemform der folgenden Formel an:

$$F = \forall x \exists y \forall z \exists w (\neg P(a, w) \vee Q(f(x), y))$$

Übung 58. Wenden Sie alle vorgestellten Umformungsschritte (bereinigen, Pränexform, Skolemform) an auf die Formel:

$$F = \forall z \exists y (P(x, g(y), z) \vee \neg \forall x Q(x)) \wedge \neg \forall z \exists x \neg R(f(x, z), z)$$

Gegeben sei eine prädikatenlogische Formel F .

- Bereinige F durch systematisches Umbenennen der gebundenen Variablen.
→ Es entsteht eine zu F äquivalente Formel F_1 .
- Binde die in F_1 vorkommenden freien Variablen y_1, \dots, y_k :
Ersetze F_1 durch $F_2 = \exists y_1 \exists y_2 \dots \exists y_k F_1$.
→ Dann ist F_2 erfüllbarkeitsäquivalent zu F_1 .
- Stelle eine zu F_2 äquivalente Formel F_3 in Pränexform her.
→ F_3 ist erfüllbarkeitsäquivalent zu F .
- Eliminiere Existenzquantoren aus F_3 durch Skolemisierung und erhalte Formel F_4 .
→ F_4 ist erfüllbarkeitsäquivalent zu F_3 und damit auch zu F .
- Da alle auftretenden Variablen jetzt allquantifiziert sind, können (zur Darstellung) alle Allquantoren weggelassen werden.
- Die so erhaltene Formel kann durch entsprechende Umformungen in disjunktive oder konjunktive Normalform überführt werden und in **Klauselform** dargestellt werden.

1 Übersicht

2 Geschichte und Anwendungen

3 Wissensrepräsentation

4 Zustandsraumsuche

5 Aussagenlogik

6 Prädikatenlogik

- Grundbegriffe
- Normalformen
- **Unentscheidbarkeit**
- Herbrand-Theorie
- Resolution

7 Prolog

Wir suchen einen algorithmischen Test für die Erfüllbarkeit oder Gültigkeit von prädikatenlogischen Formeln.

Gültigkeitsproblem der Prädikatenlogik:

gegeben: Eine prädikatenlogische Formel F .

gefragt: Ist F eine (allgemein-)gültige Formel?

Erfüllbarkeitsproblem der Prädikatenlogik:

gegeben: Eine prädikatenlogische Formel F .

gefragt: Ist F erfüllbar?

Leider können solche Algorithmen aus prinzipiellen Gründen nicht existieren, wie wir im Folgenden sehen werden.

Postsches Korrespondenzproblem:

gegeben: Eine endliche Menge von Wortpaaren $(x_1, y_1), (x_2, y_2), \dots, (x_k, y_k)$, wobei $x_i, y_i \in \Sigma^+$.

gefragt: Gibt es eine Folge von Indizes $i_1, i_2, \dots, i_n \in \{1, 2, \dots, k\}$, $n \geq 1$, mit $x_{i_1} x_{i_2} \dots x_{i_n} = y_{i_1} y_{i_2} \dots y_{i_n}$?

Beispiel: $K = ((1, 101), (10, 00), (011, 11))$ besitzt die Lösung $(1, 3, 2, 3)$, denn es gilt

$$\underbrace{1}_{x_1} \underbrace{011}_{x_3} \underbrace{10}_{x_2} \underbrace{011}_{x_3} = \underbrace{101}_{y_1} \underbrace{11}_{y_3} \underbrace{00}_{y_2} \underbrace{11}_{y_3}$$

Aus der Berechenbarkeitstheorie wissen wir, dass das Postsche Korrespondenzproblem nicht entscheidbar ist.

Mittels Reduktion kann man zeigen, dass das Gültigkeitsproblem für prädikatenlogische Formeln nicht entscheidbar ist.

Als Folgerung ergibt sich, dass auch das Erfüllbarkeitsproblem für prädikatenlogische Formeln nicht entscheidbar ist. (Eine Formel F ist gültig, genau dann wenn $\neg F$ unerfüllbar ist.)

Monadische Prädikatenlogik: Die Formeln enthalten keine Funktionssymbole und alle Prädikatsymbole sind einstellig.

- Für eine erfüllbare Aussage F der monadischen Prädikatenlogik mit den einstelligen Prädikatensymbolen P_1, \dots, P_n existiert bereits ein Modell der Mächtigkeit 2^n .
- Das Erfüllbarkeits- und das Gültigkeitsproblem für monadische prädikatenlogische Formeln ist entscheidbar.

1 Übersicht

2 Geschichte und Anwendungen

3 Wissensrepräsentation

4 Zustandsraumsuche

5 Aussagenlogik

6 Prädikatenlogik

- Grundbegriffe
- Normalformen
- Unentscheidbarkeit
- **Herbrand-Theorie**
- Resolution

7 Prolog

Problem im Umgang mit prädikatenlogischen Formeln:

- Die Definition von Strukturen $\mathcal{A} = (U_{\mathcal{A}}, I_{\mathcal{A}})$ lässt es zu, dass $U_{\mathcal{A}}$ beliebige Mengen sein können.
- Es scheint keine Möglichkeit zu geben, Aussagen über deren Mächtigkeit, geschweige denn über den Aufbau von $I_{\mathcal{A}}$ zu machen.

→ Wie sollen wir alle potenziellen Strukturen für eine gegebene Formel auf systematische Art und Weise aufzählen, um sie daraufhin auf ihre Modelleigenschaft zu untersuchen?

Arbeiten, die im wesentlichen auf Jacques Herbrand, Kurt Gödel und Thoralf Skolem zurückgehen, zeigen: Die algorithmische Suche nach potenziellen Modellen für eine Formel kann auf eine gewisse kanonische Art erfolgen bzw. beschränkt bleiben.

Sei F eine geschlossene Formel in Skolemform. Das *Herbrand-Universum* $D(F)$ wird wie folgt induktiv definiert:

- $D(F)$ enthält alle in F vorkommenden Konstanten. Falls F keine Konstanten enthält, so ist a in $D(F)$.
- Für jedes in F vorkommende n -stellige Funktionssymbol f und Terme t_1, t_2, \dots, t_n in $D(F)$ ist auch der Term $f(t_1, t_2, \dots, t_n)$ in $D(F)$.

Also: Das Herbrand-Universum besteht aus allen variablenfreien Termen, die aus den Konstanten und den Funktionssymbolen der Formel F gebildet werden können.

Beispiel: Das Herbrand-Universum zur Formel $F = \forall x \forall y \forall z P(x, f(y), g(z, x))$ ist:

$$\begin{aligned} D(F) = & \{a, f(a), g(a, a), f(f(a)), f(g(a, a)), \\ & g(f(a), a), g(a, f(a)), g(f(a), f(a)), \dots\} \end{aligned}$$

Übung 59. Geben Sie für die Formel $G = \forall x \forall y Q(c, f(x), h(y, b))$ die ersten Elemente des Herbrand-Universums an.

Wir werden im Folgenden sehen, dass es ausreichend ist, $D(F)$ als Grundbereich zu nutzen, um nach möglichen Modellen für die Formel F zu suchen.

Sei F eine Aussage in Skolemform. Dann heißt jede zu F passende Struktur $\mathcal{A} = (U_{\mathcal{A}}, I_{\mathcal{A}})$ eine **Herbrand-Struktur** für F , falls gilt:

- $U_{\mathcal{A}} = D(F)$
- Für jedes in F vorkommende n -stellige Funktionssymbol f und $t_1, t_2, \dots, t_n \in D(F)$ ist $f^{\mathcal{A}}(t_1, t_2, \dots, t_n) = f(t_1, t_2, \dots, t_n)$.

Beispiel: Eine Herbrand-Struktur $\mathcal{A} = (U_{\mathcal{A}}, I_{\mathcal{A}})$ für die Formel $F = \forall x \forall y \forall z P(x, f(y), g(z, x))$ muss folgende Bedingungen erfüllen:

$$U_{\mathcal{A}} = D(F) = \{a, f(a), g(a, a), f(f(a)), f(g(a, a)), \dots\}$$

und

Die Wahl von P^A ist noch offen. Wir könnten festlegen:

$$(t_1, t_2, t_3) \in P^{\mathcal{A}} \iff g(t_1, t_2) = g(t_2, f(t_3))$$

Ist die so definierte Struktur \mathcal{A} ein Modell für F ?

Anmerkungen:

- Bei Herbrand-Strukturen sind der Grundbereich und die Interpretation der Funktionssymbole festgelegt. Nur die Interpretation der Prädikatsymbole kann frei gewählt werden.
- Syntax und Semantik von Termen wird „gleichgeschaltet“. Terme werden „durch sich selbst“ interpretiert.
- Eine Herbrand-Struktur \mathcal{A} für eine Formel F nennen wir *Herbrand-Modell* für F , falls \mathcal{A} ein Modell für F ist.

Satz: Sei F eine Aussage in Skolemform. Dann ist F genau dann erfüllbar, wenn F ein Herbrand-Modell besitzt. (ohne Beweis)

Folgerung: Jede erfüllbare Formel der Prädikatenlogik besitzt bereits ein abzählbares Modell, also ein Modell mit abzählbarer Grundmenge.

Sei $F = \forall y_1 \forall y_2 \dots \forall y_n F^*$ eine Aussage in Skolemform. Dann ist $E(F)$, die **Herbrand-Expansion** von F , definiert als

$$E(F) = \{F^*[y_1/t_1][y_2/t_2] \cdots [y_n/t_n] \mid t_1, t_2, \dots, t_n \in D(F)\}.$$

Die Formeln in $E(F)$ entstehen also, indem die Terme in $D(F)$ in jeder möglichen Weise für die Variablen in F^* substituiert werden.

Beispiel: Für die obige Formel $F = \forall x \forall y \forall z P(x, f(y), g(z, x))$ sind die einfachsten Formeln in $E(F)$ die folgenden:

$P(a, f(a), g(a, a))$	mit	$[x/a][y/a][z/a]$
$P(f(a), f(a), g(a, f(a)))$	mit	$[x/f(a)][y/a][z/a]$
$P(a, f(f(a)), g(a, a))$	mit	$[x/a][y/f(a)][z/a]$
$P(a, f(a), g(f(a), a))$	mit	$[x/a][y/a][z/f(a)]$
$P(g(a, a), f(a), g(a, g(a, a)))$	mit	$[x/g(a, a)][y/a][z/a]$
	usw.	

Beachte: Die Formeln in $E(F)$ können letztlich als aussagenlogische Formeln behandelt werden, da sie keine Variablen enthalten.

Satz: Für jede Aussage F in Skolemform gilt: F ist erfüllbar genau dann, wenn die Formelmenge $E(F)$ im aussagenlogischen Sinn erfüllbar ist. (ohne Beweis)

Zusammenfassend kann man sagen:

- Eine prädikatenlogische Formel kann durch i.Allg. unendlich viele aussagenlogische Formeln approximiert werden.
- Diese aussagenlogischen Formeln können systematisch aufgezählt werden.

Um daraus ein Semi-Entscheidungsverfahren für die Unerfüllbarkeit von Formeln der Prädikatenlogik zu formulieren, benötigen wir noch den Endlichkeitssatz der Aussagenlogik.

Endlichkeitssatz: (Aussagenlogik)

Eine Menge \mathcal{F} von aussagenlogischen Formeln ist genau dann erfüllbar, wenn jede endliche Teilmenge von \mathcal{F} (also auch \mathcal{F} selbst) erfüllbar ist. (ohne Beweis)

Oder anders formuliert: Eine evtl. unendliche Formelmenge \mathcal{F} ist genau dann unerfüllbar, wenn bereits eine endliche Teilmenge \mathcal{F}' von \mathcal{F} unerfüllbar ist.

Satz von Herbrand:

Eine Aussage F in Skolemform ist genau dann unerfüllbar, wenn es eine endliche Teilmenge von $E(F)$ gibt, die im aussagenlogischen Sinn unerfüllbar ist. (direkte Folgerung aus obigen Sätzen)

Algorithmus von Gilmore: Semi-Entscheidungsverfahren für die Unerfüllbarkeit von Formeln der Prädikatenlogik.

- Gegeben: Eine prädikatenlogische Aussage F in Skolemform.
- Sei $E(F) = \{F_1, F_2, F_3, \dots\}$ eine beliebige aber fixierte Aufzählung der Herbrand-Expansion von F .
- Algorithmus:
 - $n := 0$;
 - repeat $n := n + 1$;
 - until $(F_1 \wedge F_2 \wedge \dots \wedge F_n)$ ist unerfüllbar

Anmerkungen:

- semi-entscheidbar $\hat{=}$ rekursiv aufzählbar
- Für unerfüllbare Formeln stoppt obiger Algorithmus, für erfüllbare Formeln nicht.
- Durch Eingabe von $\neg F$ anstelle von F wird aus dem Unerfüllbarkeitstest ein Gültigkeitstest.

Übung 60. Zeigen Sie mittels des Algorithmus von Gilmore, dass folgende Formeln unerfüllbar sind:

- $F = \exists x \forall y (\neg P(f(f(x))) \wedge P(f(y)))$
- $G = \forall x (P(f(x)) \wedge \neg P(x))$

Anmerkung: Der Algorithmus von Gilmore funktioniert zwar, ist aber in der Praxis unbrauchbar, weil er zu viele Formeln erzeugt und nicht zielgerichtet arbeitet.

Daher werden wir uns im Folgenden ansehen, wie wir das Prinzip der Resolution auch in der Prädikatenlogik anwenden können.

1 Übersicht

2 Geschichte und Anwendungen

3 Wissensrepräsentation

4 Zustandsraumsuche

5 Aussagenlogik

6 Prädikatenlogik

- Grundbegriffe
- Normalformen
- Unentscheidbarkeit
- Herbrand-Theorie
- Resolution

7 Prolog

Die Tests auf Unerfüllbarkeit können auch per aussagenlogischer Resolution erledigt werden.

Beispiel: Gegeben sei folgende unerfüllbare Formel in Skolemform:

$$F = \forall x (P(x) \wedge \neg P(f(x)))$$

Damit erhalten wir

- als Klauselform: $\{\{P(x)\}, \{\neg P(f(x))\}\}$
- als Herbrand-Universum: $D(F) = \{a, f(a), f(f(a)), \dots\}$
- als Herbrand-Expansion:

$E(F) = \{(P(a) \wedge \neg P(f(a))), (P(f(a)) \wedge \neg P(f(f(a)))), \dots\}$, oder in Klauselform
 $\{\{P(a)\}, \{\neg P(f(a))\}, \{P(f(a))\}, \{\neg P(f(f(a)))\}, \dots\}$

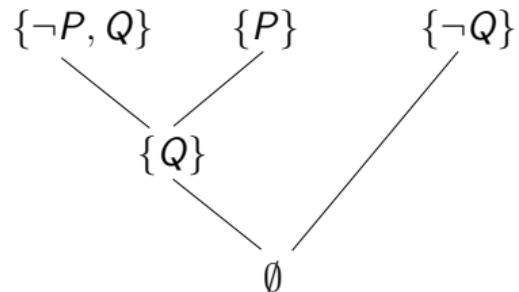
Bereits die ersten beiden Elemente von $E(F)$ reichen aus, um die Unerfüllbarkeit von F zu zeigen:

$$\begin{array}{cccc} \{P(a)\} & \{\neg P(f(a))\} & \{P(f(a))\} & \{\neg P(f(f(a)))\} \\ & \searrow & \swarrow & \\ & \emptyset & & \end{array}$$

Um besser zu verstehen, was wir hier eigentlich tun, werfen wir kurz einen Blick zurück auf die Aussagenlogik.

Aussagenlogik:

- Betrachten wir die Klauselmenge $\{\{\neg P, Q\}, \{P\}, \{\neg Q\}\}$.
- Resolutionsprinzip: Resolviere Klauseln mit komplementären Literalen.



- Führt der Resolutionsgraph auf die leere Klausel, dann ist die Formel unerfüllbar.

Aber was passiert, wenn wir aus den Variablen P und Q der obigen Formel Prädikate machen?

- Betrachten wir bspw. folgende Formel:

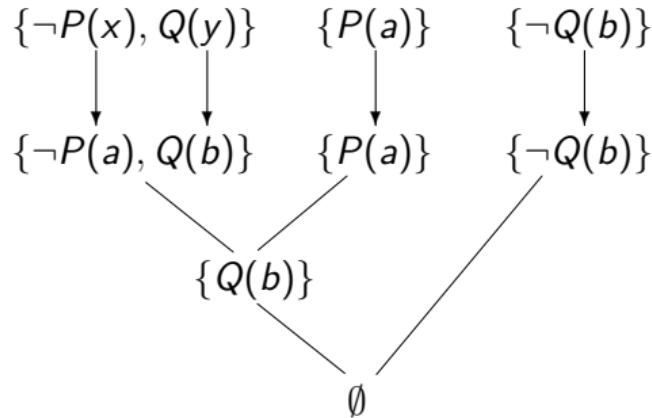
$$\forall x \forall y (P(x) \rightarrow Q(y)) \wedge P(a) \wedge \neg Q(b)$$

- Als Klauselmenge: $\{\{\neg P(x), Q(y)\}, \{P(a)\}, \{\neg Q(b)\}\}$

Sind $\neg P(x)$ und $P(a)$ komplementär?

- In einem gewissen Sinn: Ja!
- Denn obige Formel soll für alle x gelten, also insbesondere auch für $x := a$.

Im Prinzip suchen wir also Substitutionen (hier $[x/a]$ und $[y/b]$), die komplementäre „Literale“ erzeugen.



Die Herbrand-Theorie zeigt formal die Korrektheit des obigen Vorgehens und erweitert das obige Vorgehen auch auf Funktionen bzw. Terme.

Wir werden später sehen: Es ist nicht notwendig, alle Substitutionen gleich zu Beginn durchzuführen.

einige Fakten zur Unifikation:

- Jeder Term ist mit sich selbst unifizierbar.
- Terme $f(s_1, \dots, s_n)$ und $f(t_1, \dots, t_n)$ sind genau dann unifizierbar, wenn s_i und t_i für $1 \leq i \leq n$ unifizierbar sind.
- Terme $f(s_1, \dots, s_n)$ und $f(t_1, \dots, t_m)$ für $n \neq m$ sind nie unifizierbar.
- Eine Variable x und ein Term t , der x nicht enthält, sind immer unifizierbar mittels $[x/t]$.
- Eine Variable x und ein Term $t \neq x$ wie $f(x, y)$, der x enthält, sind nie unifizierbar.

Übung 61. Zeigen Sie mittels Resolution, dass $\exists y \text{ irren}(y)$ eine Folgerung ist von:

$$(\forall x \text{ Mensch}(x) \rightarrow \text{irren}(x) \wedge \text{Mensch}(\text{Max}))$$

Oder in Worten: Alle Menschen irren sich und Max ist ein Mensch, also gibt es jemanden, der sich irrt.

Problem:

Wie sollen wir effizient die Substitutionen finden, die bei einer Resolutionsherleitung zur leeren Klausel führen? Ein systematisches Durchprobieren aller Substitutionen scheint sehr aufwendig und wenig zielgerichtet zu sein.

Problem: Es müssen Entscheidungen für einige Substitutionen „vorausschauend“ getroffen werden, um Resolutionen, die im Diagramm weiter unten liegen, zu ermöglichen.

Wir wollen daher nur insoweit Substitutionen durchführen, wie es für den direkt nachfolgenden Resolutionsschritt notwendig ist.

Beispiel: Bei $\{P(x), \neg Q(g(x))\}$ und $\{\neg P(f(y))\}$ reicht die Substitution $[x/f(y)]$, um die Resolvente $\{\neg Q(g(f(y)))\}$ zu erhalten. Es ist nicht nötig, hier bereits y zu substituieren.

Wir suchen also Substitutionen, die zwei Literale (oder mehr) *unifiziert*, also identisch macht. Im obigen Beispiel unifiziert $[x/f(y)]$ die beiden Literale $P(x)$ und $P(f(y))$.

Auch die Substitution $[x/f(a)][y/a]$ würde die beiden Literale unifizieren, aber dabei wird mehr substituiert als notwendig.

Eine Substitution σ ist ein *Unifikator* einer (endlichen) Menge von Literalen $\mathcal{L} = \{L_1, L_2, \dots, L_k\}$, falls $L_1\sigma = L_2\sigma = \dots = L_k\sigma$. Wir sagen dann: \mathcal{L} ist *unifizierbar*.

Ein Unifikator σ einer Literalmenge \mathcal{L} heißt *allgemeinster Unifikator* von \mathcal{L} , falls für jeden Unifikator μ von \mathcal{L} gilt, dass es eine Substitution s gibt mit $\mu = \sigma s$.

Beispiel: Betrachten wir die Terme $f(x, g(a, y))$ und $f(b, z)$. Dann sind σ und μ zwei Unifikatoren.

$$\mu = [x/b][y/a][z/g(a, a)] \quad \sigma = [x/b][z/g(a, y)]$$

σ ist allgemeinster Unifikator, μ setzt sich dagegen aus σ und einer anderen Substitution zusammen:

$$\mu = \underbrace{[x/b][z/g(a, a)]}_{\sigma} [y/a]$$

Beispiele: Der allgemeinste Unifikator (most general unifier) von

- $\{P(x), P(f(y))\}$ ist $[x/f(y)]$.
- $\{Q(x, f(x)), Q(y, g(y))\}$ existiert nicht.
- $\{P(x), P(f(x))\}$ existiert nicht.
- $\{Q(x, f(y)), Q(g(z), f(x))\}$ ist $[x/g(z)][y/g(z)]$.

Anmerkungen:

- Der allgemeinste Unifikator zweier Terme ist eindeutig bestimmt (bis auf Variablenumbenennungen).
- Eine Menge \mathcal{L} von (mehr als zwei) Literalen kann nicht unifizierbar sein, auch wenn alle Paare von Literalen in \mathcal{L} unifizierbar sind.

Beispiel: $\{Q(x, f(y)), Q(f(y), z), Q(z, f(x))\}$

Unifikationsalgorithmus:

Eingabe: eine Literalmenge \mathcal{L}

$\sigma := []$; (leere Substitution)

while $|\mathcal{L}\sigma| > 1$ **do**

 Suche die erste Position in $\mathcal{L}\sigma$, an der sich zwei Literale
 L_1, L_2 unterscheiden

if keines der beiden Zeichen ist eine Variable

then stoppe mit „nicht unifizierbar“

else Sei x die Variable und t der Term in anderen Literal
 (möglicherweise auch eine Variable)

if x kommt in t vor

then stoppe mit „nicht unifizierbar“

else $\sigma := \sigma[x/t]$

Ausgabe: σ

Anmerkung: Die Anzahl der Resolutionsmöglichkeiten ist im Allgemeinen sehr hoch, weil

- es viele Möglichkeiten gibt, zwei Klauseln zu finden, die resolvierbar sind, um so neue Resolventen zu erzeugen.
- Resolventen bei einer Resolutionsherleitung länger werden können als ihre Ausgangsklauseln.

Für die Resolution der leeren Klausel eignen sich aber eventuell nur sehr wenige Paare von Klauseln. Wie finden wir also die „richtigen“ Klauseln zum Resolvieren?

Bei der logischen Programmierung beschränken wir uns auf Hornklauseln:

- Jede Programmklause (also eine Regel oder ein Fakt) enthält genau ein positives Literal (definite Klausel).
- Eine Zielklause (Anfrage an das System) enthält nur negative Literale.

Das hat weitreichende Folgen für die Ableitungsmöglichkeiten und die dabei erzielbare Effizienz:

- Resolvieren zweier Programmklasen kann niemals zur leeren Klausel führen.
- Die Resolution einer Zielklause und einer Programmklause führt immer wieder zu einer neuen (evtl. leeren) Zielklause.

→ SLD-Resolution: Selection rule driven Linear resolution for Definite clauses

Linear resolution bedeutet, dass mit der gerade hergeleiteten Klausel weitergearbeitet wird.

Beispiel: Das Prädikat $P(x, y)$ bedeute „ x is parent of y “. Außerdem gilt für Großeltern (englisch *grand parent*) folgende Regel:

$$\begin{aligned} \forall x \forall y \forall z (P(x, z) \wedge P(z, y)) &\rightarrow GP(x, y) \\ \equiv \forall x \forall y \forall z (\neg(P(x, z) \wedge P(z, y)) \vee GP(x, y)) \\ \equiv \forall x \forall y \forall z (\neg P(x, z) \vee \neg P(z, y) \vee GP(x, y)) \end{aligned}$$

Weiterhin gelten folgende Fakten: $P(ben, lea)$, $P(pia, otto)$ und $P(lea, tim)$. Die Regeln und die Fakten ergeben zusammen die Programmklauseeln.

$$\{P(ben, lea)\}, \{P(pia, otto)\}, \{P(lea, tim)\}, \{\neg P(x, z), \neg P(z, y), GP(x, y)\}$$

Wir fragen uns, ob $GP(ben, tim)$ aus den Programmklauseeln folgt? Dazu müssen wir zeigen, dass die Regel und die Fakten und die negierte Anfrage unerfüllbar sind.

$$\begin{array}{ccc} \{P(ben, lea)\}, \{\neg P(x, z), \neg P(z, y), GP(x, y)\} & \xrightarrow{[x/ben][z/lea]} & \{\neg P(lea, y), GP(ben, y)\} \\ \{\neg P(lea, y), GP(ben, y)\}, \{P(lea, tim)\} & \xrightarrow{[y/tim]} & \{GP(ben, tim)\} \\ \{GP(ben, tim)\}, \{\neg GP(ben, tim)\} & \rightarrow & \emptyset \end{array}$$

Die hier vorgestellte Prädikatenlogik nennt man *Prädikatenlogik erster Stufe* oder auch *Prädikatenlogik erster Ordnung*.

- PL1 erweitert die Aussagenlogik um Quantoren, Prädikate und Terme.
- Leider lassen sich mit PL1 viele wichtige Formeln nicht ausdrücken, bspw. das Induktionsaxiom der Peano-Axiome:

$$\forall P (P(0) \wedge (\forall x P(x) \rightarrow P(x + 1))) \rightarrow \forall x P(x)$$

- Die *Prädikatenlogik zweiter Ordnung* erlaubt Quantifizierungen auch über Funktions- und Prädikatsymbole.
- Das macht die Sache nicht leichter: Viele Eigenschaften, die in PL1 entscheidbar oder semi-entscheidbar sind, sind in PL2 unentscheidbar.

1 Übersicht

2 Geschichte und Anwendungen

3 Wissensrepräsentation

4 Zustandsraumsuche

5 Aussagenlogik

6 Prädikatenlogik

7 Prolog

1 Übersicht

- Allgemeines

- Erste Schritte

- Arithmetik

- Listen

- Backtracking

- Sortieren

- Input/Output

- Zahlenrätsel

- Kannibalen und Missionare

- 8-Damen-Problem

- Schiebepuzzle

- A^* -Algorithmus

4 Zustandsraumsuche

5 Aussagenlogik

6 Prädikatenlogik

7 Prolog

Algorithm = Logic + Control

- imperative Programmierung bspw. in C, C++ oder Java: Angabe eines Algorithmus zum Lösen des Problems.
 - WIE ist ein Problem zu lösen?
- deklarative Programmierung bspw. in Prolog: Nur Angabe des Problems.
 - WAS ist zu lösen - nicht wie. (Idealfall)
 - LISP, Haskell (funktionale Sprachen), SQL (Abfragesprache), Prolog (logische Sprache), Integer Programming (?)
- Dieser Idealfall wird bei existierenden Prolog-Systemen mit depth-first Auswertungsstrategie nicht erreicht.
- Die breadth-first Auswertungsstrategie ist zwar vollständig, aber hoffnungslos ineffizient.

→ Wir müssen einen Kompromiss finden zwischen dem Idealfall (vollständige Trennung von Logik- und Kontrollkomponente) und Effizienz.

- Programmiersprache für Logik-Programme
- kennt zusätzlich Meta-Befehle, Ein-/Ausgabe und Arithmetik
- Im Gegensatz zu reinen Logik-Programmen wird das WIE durch die Verarbeitungsreihenfolge bestimmt.
- David H.D. Warren:
“Prolog ist [...] ein Werkzeug für das Denken.“
- Basiert auf Ideen von Kowalski und Colmerauer.
- Erste Implementierung 1972 in Marseille.
- Aufschwung durch 5th Generation-Projekt.
- Neben LISP die wichtigste Sprache der KI.
- Einsatzgebiete: Expertensysteme, Rule Engines
- Warren Abstract Machine: Virtuelle Machine, die kompilierten Prolog-Code ausführen kann (z.B. GNU Prolog).
- 1995 Standardisierung: ISO/IEC 13211-1, vorher viele Dialekte

Literatur

- W.F. Clocksin, C.S. Mellish:

Programming in Prolog.

Springer, New York, 1981

- L. Sterling, E. Shapiro:

Prolog - Fortgeschrittene Programmiertechniken.

Addison-Wesley, Bonn, 1988

- Ivan Bratko:

Prolog – Programming for Artificial Intelligence.

3rd edition, Addison-Wesley, 2000.

Es gibt syntaktische Konventionen, um verschiedene Programmbestandteile zu unterscheiden:

- Variablen: Großschreibung
- Prädikate und Funktionssymbole: Kleinschreibung
- Jede Klausel wird mit einem Punkt abgeschlossen.

In einer konkret einsetzbaren Sprache brauchen wir Konzepte, um Daten einzulesen, auszugeben oder zu bearbeiten: System stellt Prädikate wie `read` oder `write` bereit.

- Können vom Benutzer nicht verändert werden.
- Haben vom logischen Gesichtspunkt keine Bedeutung.
- Werden bei Bearbeitung durch Prologs Auswertemechanismus einfach übergangen.
- Erzeugen aber Seiteneffekte wie schreiben auf den Bildschirm oder in eine Datei.

Man muss sich über die Abfolge der Auswertung eines Prolog-Programms bewusst sein:

- Eine Zielklausel wie

```
?- read(X), compute(X,Y), write(Y).
```

kann sinnvoll nur von links nach rechts ausgewertet werden.

- Im Gegensatz zu den theoretischen Betrachtungen: Nur Klauseln ohne Seiteneffekte können auch in einer anderen Reihenfolge ausgewertet werden.

Andere Prädikate erzwingen Variableninstanziierungen:

- Trifft das Auswertesystem bspw. auf `is(X, Y*5)` (oder in Infix-Notation `X is Y*5`), wobei `Y` bereits mit der Konstanten 7 belegt ist, so wird `X` mit 35 belegt.
→ Auf diese Art können arithmetische Berechnungen in Prolog realisiert werden.

1 Übersicht

- Allgemeines
- **Erste Schritte**
- Arithmetik
- Listen
- Backtracking
- Sortieren
- Input/Output
- Zahlenrätsel
- Kannibalen und Missionare
- 8-Damen-Problem
- Schiebepuzzle
- A^* -Algorithmus

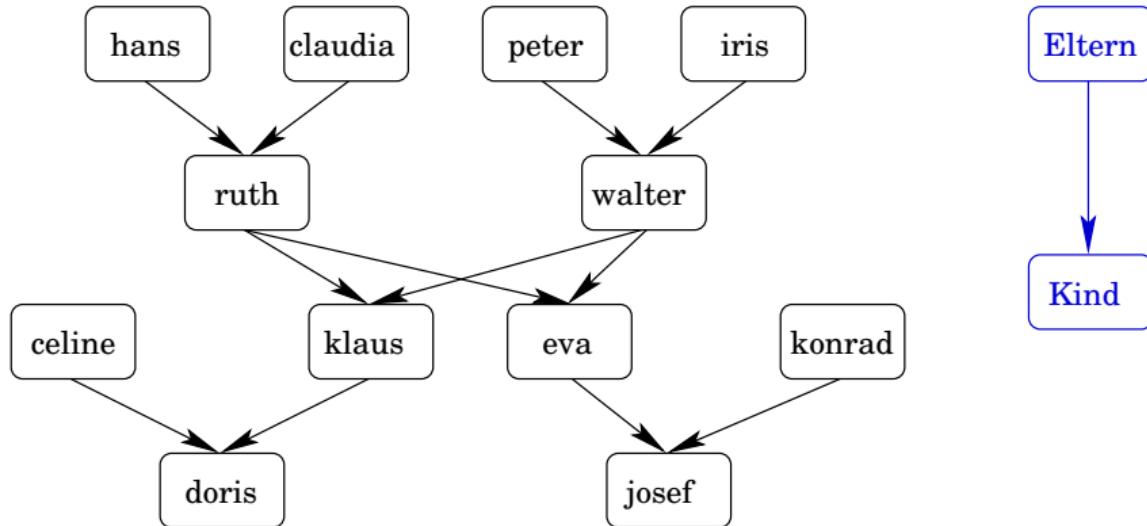
4 Zustandsraumsuche

5 Aussagenlogik

6 Prädikatenlogik

7 Prolog

Wir wollen folgende Verwandschaftsbeziehung in Prolog darstellen:



Dazu definieren wir folgende Fakten:

```
parent(hans, ruth).  
parent(claudia, ruth).  
parent(peter, walter).  
parent(iris, walter).  
parent(ruth, klaus).  
parent(walter, klaus).
```

```
parent(ruth, eva).  
parent(walter, eva).  
parent(celine, doris).  
parent(klaus, doris).  
parent(eva, josef).  
parent(konrad, josef).
```

Dabei bezeichnet `parent(x, y)` den Sachverhalt, dass y das Kind von x ist. Wir lesen `parent(x, y)` also als x is parent of y.

Fakten sind Prädikate ohne Variablen.

Sie finden im Internet frei verfügbare Prolog-Interpreter z.B. unter:

- <http://www.gprolog.org/>
- <https://www.swi-prolog.org/>
- <http://jlogic.sourceforge.net/>

Das Manual zu GNU-Prolog finden Sie unter

<http://www.gprolog.org/manual/gprolog.html>

Freie Prolog-Tutorials finden Sie bspw. unter:

- <http://www.learnprolognow.org/>
- https://www.cpp.edu/~jrfisher/www/prolog_tutorial/contents.html
- <https://ktiml.mff.cuni.cz/~bartak/prolog/>

Die Erläuterungen in diesem Kapitel beziehen sich auf den Prolog-Interpreter von GNU, gelten mit Einschränkungen aber auch für SWI-Prolog.

Nachdem wir obige Fakten als Programm in der Datei `intro.pl` gespeichert haben, können wir es am Kommando-Prompt des Interpreters einlesen:

```
| ?- [intro].
```

Falls das Programm syntaktisch korrekt ist, sollte so etwas ausgegeben werden wie:

```
compiling intro.pl for byte code...
intro.pl compiled, 12 lines read
```

```
yes
| ?-
```

Wenn Sie stattdessen das Programm mittels der Tastatur direkt eingeben wollen:

- Nach der Eingabe von `[user].` kann der Benutzer Regeln und Fakten definieren.
- Mittels `Ctrl-D` wird die Eingabe beendet und automatisch der Übersetzungsvorgang gestartet.

Um jederzeit feststellen zu können, welches Programm gerade aktiv ist, geben wir folgendes ein:

```
| ?- listing.
```

Was kann man nun mit diesem Programm machen?

- Wir können fragen, ob Ruth ein Kind von Walter ist:

```
| ?- parent(walter, ruth).  
no
```

- Da Prolog annimmt, seine Fakten würden die ganze Welt komplett beschreiben, ist wahr, was gefunden wird und falsch, was nicht vorhanden ist.

Wie funktioniert das?

- Prolog vergleicht die Anfrage mit den Fakten und Regeln der Wissensbasis und prüft, ob der Funktor mit gleicher Stelligkeit vorhanden ist.
- Der Term `walter` wird mit denen der Fakten verglichen, bei Übereinstimmung wird dasselbe mit `ruth` durchgeführt.

→ Diesen Vorgang nennt man *matchen*.

Was kann man sonst noch mit diesem Programm machen?

- Wir können die Kinder von Walter auflisten:

```
| ?- parent(walter, X).
```

- Antwort:

```
X = klaus ? ; % mit dem Semikolon wird
X = eva          % die nächste Lösung angefordert
```

- Die gleiche Anfrage mit SQL auf die Tabelle Eltern:

Parent	Child
--------	-------

ruth	klaus	
walter	klaus	Select Child from Eltern
ruth	eva	where Parent = 'walter';
walter	eva	
...	...	

Wie funktioniert das?

- Prolog durchsucht die Fakten (von oben nach unten) und testet, ob `walter` als erster Term vorkommt (matchen).
- Anschließend wird `X` mit `klaus` *instanziert*. (besser: belegt)
- Diesen Vorgang nennt man *Unifikation* oder *Instanziierung*.

Ersetzen der Variablen durch Terme, so dass die Terme als Zeichenfolge gleich sind.

- Die gefundene Belegung wird ausgegeben.
- Die Lösungssuche endet noch nicht, da noch ungeprüfte Klauseln existieren.
- Die Lösungssuche wird bei der letzten Alternative fortgesetzt; alle Variablen, die ab diesem Punkt instanziert wurden, werden wieder frei.
- Diesen Vorgang nennt man *Backtracking*.

Was kann man noch mit diesem Programm machen?

- Wir können die Eltern von Walter auflisten:

| ?- parent(X, walter).

- Bedeutung der Anfrage: Für welche X lässt sich das Ziel parent(X, walter) aus den Fakten folgern?

- Antwort:

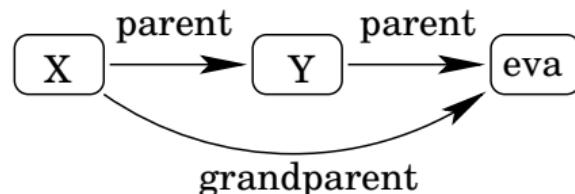
```
X = peter ? a  % mit dem 'a' werden alle
X = iris          % restlichen Lösung angefordert
no
```

Man kann „neues Wissen“ mit dem Programm generieren:

- Wir können die Großeltern von Eva ausgeben:

| ?- parent(Y, eva), parent(X, Y).

- Zur Veranschaulichung:



- Das Komma ist als logisches UND zu lesen. Ausgabe:

X = hans Y = ruth ? ;

X = claudia Y = ruth ? ;

X = peter Y = walter ? ;

X = iris Y = walter ? ;

no

Wie funktioniert das?

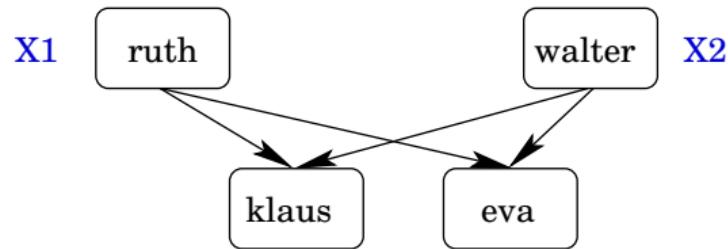
- Zielliste: `parent(Y, eva), parent(X, Y).`
 - Das Programm wird von oben nach unten durchsucht, und der passende Fakt 7 gefunden: `parent(ruth, eva)`
 - Also wird `Y=ruth` instanziert, das erste Literal ist `true` und wird aus der Zielliste entfernt.
- Zielliste: `parent(X, ruth).`
 - Wieder wird das Programm von oben nach unten durchsucht und Fakt 1 gefunden: `parent(hans, ruth)`
 - Also wird `X=hans` instanziert, das erste Literal der aktuellen Zielliste ist `true` und wird aus der Zielliste entfernt.
- Die Zielliste ist leer, damit ist die Anfrage erfüllt und die Instanziierung `X=hans, Y=ruth` wird ausgegeben.

Wird eine weitere Lösung angefordert, wird die Instanziierung von X wieder rückgängig gemacht und die Suche wird vor der letzten Instanziierung fortgesetzt. → Backtracking

- Zielliste: `parent(X,ruth).`
 - Im Programm wird Fakt 2 gefunden: `parent(claudia,ruth)`
 - `X=claudia` wird instanziert, das erste Literal der aktuellen Zielliste ist `true` und wird aus der Zielliste entfernt.
- Die Zielliste ist wieder leer, die nächste Lösung `X=claudia, Y=ruth` wird ausgegeben usw.

Wie können wir testen, ob zwei Personen Geschwister sind?

- Wenn Eva und Klaus Geschwister sind, haben sie einen gemeinsamen Elternteil X:
| ?- parent(X, eva), parent(X, klaus).
- Zur Veranschaulichung:



- Ausgabe:
X = ruth ? ; % mit dem Semikolon wird
X = walter ? ; % die nächste Lösung angefordert
no

Wie können wir zwischen Mutter und Vater unterscheiden?

- Zur Unterscheidung männlich/weiblich fügen wir dem Programm zwei Relationen hinzu:

male(hans).	female(claudia).
male(peter).	female(iris).
male(walter).	female(ruth).
male(klaus).	female(celine).
male(konrad).	female(eva).
male(josef).	female(doris).

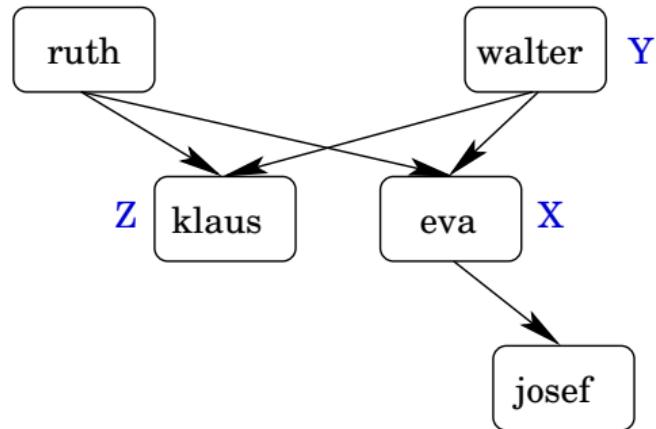
- Damit können wir z.B. Walters Vater und Mutter unterscheiden:

Vater: | ?- parent(X, walter), male(X).

Mutter: | ?- parent(X, walter), female(X).

Wie können wir Onkel und Tanten von einer Person bestimmen?

- Josefs Onkel und Tante sind Geschwister seiner Eltern:
| ?- parent(X,josef), parent(Y,X), parent(Y,Z), X \== Z.
- Zur Veranschaulichung:



- Hier muss zwingend X ungleich Z gelten! In Prolog: X \== Z

Wie können wir einem Programm *Regeln* hinzufügen?

- *Regeln:*

```
mother(X,Y) :- parent(X,Y), female(X).  
father(X,Y) :- parent(X,Y), male(X).
```

- *Semantik:*

$\forall X \forall Y$ gilt: $\text{parent}(X,Y) \wedge \text{female}(X) \Rightarrow \text{mother}(X,Y)$

- *Sprechweise:*

X is the mother of Y, if X is a parent of Y and X is female.

Im Folgenden definieren wir Regeln für

- Großeltern, -vater und -mutter.
- Geschwister, Schwester, Bruder.
- Onkel und Tante.
- eine allgemeine Vorfahr-Beziehung.

Großeltern, Großvater und Großmutter:

- *Regeln:*

```
grandparent(X,Y) :- parent(X,Z), parent(Z,Y).  
grandfather(X,Y) :- grandparent(X,Y), male(X).  
grandmother(X,Y) :- grandparent(X,Y), female(X).
```

- *Semantik:* $\forall X \forall Y \forall Z$ gilt:

$$\text{parent}(X,Z) \wedge \text{parent}(Z,Y) \Rightarrow \text{grandparent}(X,Y)$$

- *Sprechweise:*

X is grandparent of Y, if X is parent of Z and Z is parent of Y.

- *Beispiel:*

```
| ?- grandparent(X,josef).  
X = ruth ? ;  
X = walter ? ;  
no
```

Wie funktioniert das?

- Zielliste: `grandparent(X, josef)`.
 - Das Programm wird von oben nach unten durchsucht und die erste passende Regel gefunden:
`grandparent(X, Y) :- parent(X, Z), parent(Z, Y).`
 - Also wird $Y=josef$ instanziert und der Eintrag der Zielliste wird ersetzt durch die rechte Seite der Regel.
- Zielliste: `parent(X, Z), parent(Z, josef)`.
 - Es wird eine passende Regel für den ersten Eintrag der Zielliste gesucht und die Regel `parent(hans, ruth)` gefunden.
 - Also wird $X=hans$ und $Z=ruth$ instanziert und der erste Eintrag der Zielliste durch `true` ersetzt, also entfernt.
- Zielliste: `parent(ruth, josef)`.
 - Dieser Fakt wird nicht im Programm gefunden, das Ziel ist mit dieser Instanzierung nicht erfüllt.
 - Die letzte Belegung wird zurückgenommen und als Zielliste ergibt sich wieder:
`parent(X, Z), parent(Z, josef)`.

Wie funktioniert das? (Fortsetzung)

- Zielliste: `parent(X,Z)`, `parent(Z,josef)`.
 - Es wird der nächste Fakt `parent(claudia, ruth)` untersucht und $X=claudia$ und $Z=ruth$ instanziert.
 - Der erste Eintrag der Zielliste wird durch `true` ersetzt, also entfernt.
- Zielliste: `parent(ruth,josef)`.
 - Wieder wird kein übereinstimmender Fakt gefunden und ein Backtracking durchgeführt.
- Zielliste: `parent(X,Z)`, `parent(Z,josef)`.
 - Dieser Vorgang wiederholt sich so lange, bis der Fakt `parent(ruth,eva)` gefunden wird, also $X=ruth$ und $Z=eva$.
- Zielliste: `parent(eva,josef)`
 - Dieses Ziel wird als Fakt gefunden und die Instanziierung $X=ruth$ ausgegeben. Der Wert von Z wird nicht ausgegeben, da er nicht in der ursprünglichen Zielliste auftaucht.

Geschwister haben einen gemeinsamen Elternteil:

- *Regeln:*

```
sibling(X,Y) :- parent(Z,X), parent(Z,Y), X \== Y.  
sister(X,Y) :- sibling(X,Y), female(X).  
brother(X,Y) :- sibling(X,Y), male(X).
```

- *Semantik:* $\forall X \forall Y \forall Z$ gilt:

$$\text{parent}(Z,X) \wedge \text{parent}(Z,Y) \wedge X \neq Y \Rightarrow \text{sibling}(X,Y)$$

- *Sprechweise:*

X is sibling of Y, if Z is parent of X and Z is parent of Y and X is not equal to Y.

- Onkel und Tante

```
aunt(X,Y) :- sibling(X,Z), parent(Z,Y), female(X).
```

```
uncle(X,Y) :- sibling(X,Z), parent(Z,Y), male(X).
```

- eine allgemeine Vorfahr-Beziehung *mittels Rekursion*

```
ancestor(X,Y) :- parent(X,Y).
```

```
ancestor(X,Y) :- parent(X,Z), ancestor(Z,Y).
```

1 Übersicht

- Allgemeines
- Erste Schritte
- **Arithmetik**
- Listen
- Backtracking
- Sortieren
- Input/Output
- Zahlenrätsel
- Kannibalen und Missionare
- 8-Damen-Problem
- Schiebepuzzle
- A^* -Algorithmus

4 Zustandsraumsuche

5 Aussagenlogik

6 Prädikatenlogik

7 Prolog

Die bekannten arithmetischen Operationen sind definiert:

+ Addition	/ Division (floating point)
- Subtraktion	// Division (integer)
* Multiplikation	mod Rest bei ganzzahliger Division

Allerdings wird die Anfrage

```
| ?- X = 1 + 2.
```

nicht mit $X = 3$, sondern mit $X = 1 + 2$ beantwortet!

Der Ausdruck $1 + 2$ ist in Prolog ein Term, wobei $+$ die Funktion und 1 und 2 die Operanden sind. Die Addition wird nur dann durchgeführt, wenn der Operator **is** verwendet wird:

```
| ?- X is 1 + 2.
```

Werden numerische Werte verglichen, erfolgt auch automatisch eine Auswertung der arithmetischen Ausdrücke:

```
| ?- 7 * 3 > 20.  
yes
```

```
| ?- 7 * 3 < 20.  
no
```

Dies gilt für die folgenden Operatoren:

$X > Y$	X is greater than Y
$X < Y$	X is less than Y
$X \geq Y$	X is greater than or equal to Y
$X \leq Y$	X is less than or equal to Y
$X =:= Y$	the values of X and Y are equal
$X =\neq Y$	the values of X and Y are not equal

Beachten Sie den Unterschied zwischen = und =:= sowie den Unterschied zwischen \== und =\=.

Wichtig: Machen Sie sich den Unterschied zwischen den beiden Operatoren `=` und `=:=` klar!

- Bei `X = Y` versucht Prolog, die Objekte `X` und `Y` zu unifizieren (gleich zu machen) und ggf. mit Werten zu belegen.

```
| ?- 1 + 2 = 2 + 1.      | ?- 1 + X = Y + 3.
```

no

X = 3

Y = 1

yes

- Der Operator `=:=` wertet den arithmetischen Ausdruck aus, belegt die Variablen aber nicht mit Werten.

```
| ?- 1 + 2 =:= 2 + 1.      | ?- 1 + X =:= Y + 3.
```

yes

uncaught exception:

Im zweiten Beispiel hätten `X` und `Y` vorher mit Werten belegt werden müssen, z.B. `X=4, Y=2, 1+X =:= Y+3.`

Test auf Gleichheit:

- = unifizierbar
- == identisch mit
- =:= numerisch gleich

Test auf Ungleichheit:

- \= nicht unifizierbar
- \== nicht identisch mit
- =\= numerisch ungleich

Beispiel:

```
| ?- X=1+3, Y=2+2, X=:=Y.  
yes
```

Beim Vergleich $X=:=Y$ werden die Terme $1+3$ und $2+2$ zunächst ausgewertet und dann verglichen.

```
| ?- X=1+3, Y=2+2, X==Y.  
no
```

Bei dem Vergleich $X==Y$ wird geprüft, ob die Inhalte von X und Y identisch sind (ohne eine arithmetische Auswertung).

Beispiel:

```
| ?- 1+X = 1+Y.  
Y = X  
yes
```

Die Variablen X und Y können unifiziert werden. Hier sieht man, das Prolog einen allgemeinsten Unifikator sucht. Es werden nicht alle Möglichkeiten aufgezählt wie $X=1, Y=1$ und $X=2, Y=2$ usw., stattdessen wird nur die „minimale“ Unifikation erzeugt.

```
| ?- 1+X == 1+Y.  
no
```

Prolog versucht nicht, die Terme gleich zu machen, es findet hier keine Unifikation statt, es werden lediglich zwei Zeichenketten miteinander verglichen.

Übung 62. Schreiben Sie ein Prädikat `maximum(X, Y, Z, Erg)`, das den maximalen Wert der drei Variablen X, Y und Z bestimmt und in Erg bereit stellt.

Übung 63. Schreiben Sie ein Prädikat `fib(N, Erg)`, das die N-te Fibonacci-Zahl F_N in Erg berechnet.

Übung 64. Schreiben Sie ein Prädikat `ggT(X, Y, Erg)` zur Berechnung des größten gemeinsamen Teilers zweier ganzer Zahlen X und Y.

Zur Erinnerung:

$$ggT(x, y) = \begin{cases} x, & \text{falls } y = 0 \\ ggT(y, x \bmod y), & \text{sonst} \end{cases}$$

In Prolog können wir zur Laufzeit Fakten und Regeln der Datenbasis hinzufügen.

- `asserta(term)` fügt `term` am Anfang der Datenbasis ein.
- `assertz(term)` fügt `term` am Ende der Datenbasis an.
- `retract(term)` entfernt `term` wieder aus der Datenbasis.

Damit das funktioniert, muss der Term entweder unbekannt sein, oder das Prädikat muss als `dynamic` vereinbart sein.

Um die Laufzeit des `fib`-Prädikats zur Berechnung der Fibonacci-Zahlen zu verbessern, vermeiden wir rekursive Aufrufe durch memorieren bereits berechneter Werte.

```
:- dynamic(fib/2).  
  
fib(0,0).  
fib(1,1).  
fib(N, Erg) :-  
    N > 0,  
    N1 is N-1,  
    N2 is N-2,  
    fib(N1,E1),  
    fib(N2,E2),  
    Erg is E1+E2,  
    asserta(fib(N, Erg)).
```

Vergleichen Sie die Laufzeiten dieser und der zuvor erstellten Lösung. Wie groß darf die Eingabe N werden?

Ändert sich die Laufzeit, wenn assertz anstelle von asserta verwendet wird? Lassen Sie sich das Programm mittels listing anzeigen.

Übersicht

1 Übersicht

- Allgemeines

- Erste Schritte

- Arithmetik

• Listen

- Backtracking

- Sortieren

- Input/Output

- Zahlenrätsel

- Kannibalen und Missionare

- 8-Damen-Problem

- Schiebepuzzle

- A^* -Algorithmus

4 Zustandsraumsuche

5 Aussagenlogik

6 Prädikatenlogik

7 Prolog

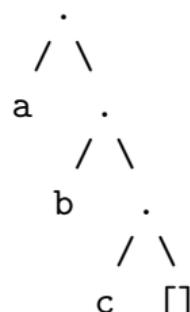
Eine Liste ist eine Aufzählung von Elementen und wird in Prolog in eckigen Klammern [...] geschrieben:

```
[adam, eva, heidi, peter, bonnie, clyde]  
[0, 1, 2, 3, 4, 5, 6, 7, 8, 9]
```

Wir können eine Liste [a,b,c] auch in Paar-Schreibweise angeben:

```
.(a,.(b,.(c,[])))
```

Listen werden in Prolog als entartete Binäräbäume gespeichert:



Daraus ergibt sich die dritte Darstellung: Aufzählung mit Restliste

- Eine leere Liste wird geschrieben als [] .
- Eine nicht-leere Liste besteht immer
 - aus dem ersten Element, Kopf (engl.: head) der Liste genannt,
 - und dem Rest, Schwanz (engl.: tail) der Liste genannt.

Der senkrechte Strich teilt den Kopf vom Schwanz der Liste:

$L = [a, b, c, d]$

$L = [a \mid Tail]$

Unifizieren wir $[X \mid Rest]$ mit $[1, 2, 3, 4]$, dann erhalten wir:

$X = 1$

$Rest = [2, 3, 4]$

Listen können auch ineinander verschachtelt werden:

```
| ?- Hobbies1 = [rennen, tanzen],  
    Hobbies2 = [schlafen, essen],  
    L = [heidi, Hobbies1, peter, Hobbies2].
```

```
Hobbies1 = [rennen, tanzen]  
Hobbies2 = [schlafen, essen]  
L = [heidi, [rennen, tanzen], peter, [schlafen, essen]]
```

Wir betrachten im Weiteren folgende Operationen:

- `member(X, L)` testet, ob das Objekt X in der Liste L enthalten ist.
- `sublist(L1, L)` testet, ob L1 eine Teilliste von L ist.
- `permutation(L, P)` erzeugt in P alle Permutationen der in L enthaltenen Objekte.

`member(X, L)` testet, ob das Objekt X in der Liste L enthalten ist:

```
| ?- member(b, [a,b,c]).
```

true

```
| ?- member(b, [a,[b,c],d]).
```

no

```
| ?- member([b,c], [a,[b,c],d]).
```

true

X ist Element der Liste L, wenn

- X der Kopf der Liste ist, also

```
member(X, [X|Tail]).
```

- oder X im Rest der Liste enthalten ist, also

```
member(X, [Head|Tail]) :- member(X, Tail).
```

Übung 65. Schreiben Sie eine Funktion `conc(L1, L2, L)`, die die Listen L1 und L2 aneinander hängt. In der Ergebnisliste L stehen also zunächst alle Elemente von L1, dann alle Elemente von L2.

Übung 66. Schreiben Sie eine Funktion `add(X,L1,L)`, die ein Element X am Anfang der Liste L1 einfügt, Liste L ist die Ergebnisliste.

Übung 67. Schreiben Sie eine Funktion `del(X,L1,L)`, die ein Element X aus der Liste L1 entfernt und Liste L liefert.

Was liefert der Aufruf `del(1, L, [2,3,4]).`?

Übung 68. Schreiben Sie eine Funktion `insert(X,L1,L)`, die ein Element X an einer beliebigen Stelle der Liste L1 einfügt und Liste L liefert.

Debugging: Mittels `trace` aktivieren Sie den Debugger, mittels `notrace` wird der Debugger ausgeschaltet.

```
| ?- trace.  
| ?- insert(1, [4,3,2], L).  
    1      1  Call: insert(1,[4,3,2],_22) ?  
    1      1  Exit: insert(1,[4,3,2],[1,4,3,2]) ?  
  
L = [1,4,3,2] ? ;  
    1      1  Redo: insert(1,[4,3,2],[1,4,3,2]) ?  
    2      2  Call: insert(1,[3,2],_55) ?  
    2      2  Exit: insert(1,[3,2],[1,3,2]) ?  
    1      1  Exit: insert(1,[4,3,2],[4,1,3,2]) ?  
| ?- notrace.
```

`sublist(L1, L)` testet, ob L1 eine Teilliste von L ist:

```
| ?- sublist([c,d,e], [a,b,c,d,e,f]).
```

true

```
| ?- sublist([c,e], [a,b,c,d,e,f]).
```

no

S ist eine Teilliste von L, wenn

- L in zwei Listen L1 und L2 aufgeteilt werden kann und
- die Liste L2 wiederum in die Liste S und eine Liste L3 aufgeteilt werden kann.

```
sublist(S,L) :- conc(L1,L2,L), conc(S,L3,L2).
```

- Stellen Sie diesen Sachverhalt graphisch dar.
- Was liefert der Aufruf `sublist(S, [1,2,3]).?`

Übung 69. Die in gprolog eingebaute Funktion sublist verhält sich etwas anders:

```
| ?- sublist([c,e], [a,b,c,d,e,f]).
```

```
true
```

```
| ?- sublist([e,c], [a,b,c,d,e,f]).
```

```
no
```

Wie könnte diese Funktion implementiert sein?

Übung 70. Schreiben Sie eine Funktion `max(L, X)`, die zu einer Liste L von Zahlen das Maximum dieser Zahlen in X ermittelt.

`permutation(L, P)` erzeugt in P alle Permutationen der in L enthaltenen Objekte

```
| ?- permutation([a,b,c], P).  
P = [a,b,c] ;  
P = [a,c,b] ;  
P = [b,a,c] ;  
....
```

Mögliche Implementierung:

- Abbruchbedingung: `permutation([], [])`.
- Falls die erste Liste die Form `[X|L]` hat: Erstelle zunächst Liste L1 als Permutation von L, füge dann X an jeder Stelle in L1 ein.

```
permutation([X|L], P) :- permutation(L, L1),  
                      insert(X,L1,P).
```

Übung 71. Geben Sie eine mögliche Implementierung der in gprolog eingebauten Relation `reverse` an.

Beispiel: `reverse([a,b,c,d] , P)`. liefert `P = [d,c,b,a]`

Übung 72. Definieren Sie eine Relation `shift(L1, L2)`, so dass L2 aus L1 hervorgeht, indem die Elemente zyklisch nach links verschoben werden.

Beispiel:

```
| ?- shift([a,b,c,d,e] , L1),  
        shift(L1, L2).
```

liefert

```
L1 = [b,c,d,e,a]  
L2 = [c,d,e,a,b]
```

Übung 73. Schreiben Sie ein Prädikat `lastElem(L, X)`, das das letzte Listenelement der Liste L in der Variablen X liefert.

Übung 74. Schreiben Sie Prädikate, mit denen man feststellen kann, ob eine Liste Präfix (bzw. Suffix) einer anderen Liste ist.

Anonyme Variablen: Häufig benötigt man einen Wert nicht weiter. In einem solchen Fall kann man eine anonyme Variable verwenden, die mit einem Unterstrich beginnt. Ihr Wert wird nicht gespeichert:

```
erstesElement(X, [X|_Rest]).
```

1 Übersicht

- Allgemeines
- Erste Schritte
- Arithmetik
- Listen
- **Backtracking**
- Sortieren
- Input/Output
- Zahlenrätsel
- Kannibalen und Missionare
- 8-Damen-Problem
- Schiebepuzzle
- A^* -Algorithmus

4 Zustandsraumsuche

5 Aussagenlogik

6 Prädikatenlogik

7 Prolog

Damit Prolog für praktische Probleme zugänglicher wird, gibt es den Cut-Operator '!', mit dem das Backtracking durch Teilbäume des Regelwerks unterbunden werden kann.

Die Lösungsmenge ist dann zwar nicht mehr in jedem Fall identisch, aber Programme können unter Performance-Aspekten optimiert werden.

Steht in einer Klausel ein Cut und wird diese Stelle bei der Auswertung erreicht, so werden alle Belegungen, die beim Matching der vorangehenden Prädikate getroffen wurden eingefroren. Für sie findet kein Backtracking mehr statt, es werden auch keine Klauseln der gleichen Prozedur mehr ausprobiert.

Scheitert der Regelteil hinter dem Cut, so scheitert die gesamte Prozedur.

Der Cut: grüne und rote Cuts

Ein Cut kann eingesetzt werden, um die Berechnung zu beschleunigen, ohne dass Lösungen verlorengehen oder hinzukommen. Solche Cuts heißen *grüne Cuts*.

```
minimum(X,Y,X) :- X < Y, !.  
minimum(X,Y,Y) :- X >= Y, !.
```

Der zweite Cut kann weggelassen werden, da die Prozedur `minimum` dann abgeschlossen ist. (Eine Zusammenfassung von „Regeln gleichen Namens“ nennt man auch Prozedur.)

Ohne Cuts hat das Programm die gleiche Lösungsmenge.

Der Cut: grüne und rote Cuts

Alternativ:

```
minimum(X,Y,Z) :- X < Y, !, Z=X.  
minimum(X,Y,Y).
```

Hier berücksichtigt man die SLD-Strategie: Auswerten der Klauseln von oben nach unten und innerhalb einer Klausel von links nach rechts.

- Aufruf `minimum(2,3,3)` liefert bei Verwendung des Cuts no.
 - Zunächst wird `X < Y` als true bewertet, der Cut wird als true interpretiert, die Unifikation `Z=X` schlägt fehl.
 - Deshalb geht der Prolog-Interpreter die Literale der Klausel zurück, um ein Backtracking zu ermöglichen.
 - Dabei trifft er auf den Cut, das Backtracking wird - auf dieser Ebene - abgebrochen, damit ist insgesamt die Auswertung fehlgeschlagen.
- Der Aufruf `minimum(2,3,3)` liefert ohne Verwendung des Cuts yes.
- Dies ist ein *roter Cut*.

Übersicht

1 Übersicht

- Allgemeines
- Erste Schritte
- Arithmetik
- Listen
- Backtracking
- **Sortieren**
- Input/Output
- Zahlenrätsel
- Kannibalen und Missionare
- 8-Damen-Problem
- Schiebepuzzle
- A^* -Algorithmus

4 Zustandsraumsuche

5 Aussagenlogik

6 Prädikatenlogik

7 Prolog

Idee:

- Tausche zwei benachbarte Zahlen X und Y , falls $X > Y$.
- Sortiere den Rest.

```
% Wenn ein Wertepaar getauscht wurde, also swap erfolgreich
% war, darf die nächste Regel NICHT ausgeführt werden!
% Roter Cut!
bubblesort(List, SortedList) :-
    swap(List, List2), !,
    bubblesort(List2, SortedList).

bubblesort(Sorted, Sorted).

swap([X,Y|Rest], [Y,X|Rest]) :- X > Y.
swap([Z|Rest], [Z|Rest2]) :- swap(Rest, Rest2).
```

Idee: Sortiere nicht-leere Liste $L=[X|Tail]$ wie folgt:

- Sortiere den Rest Tail der Liste L zu SortedTail.
- Füge X an der richtigen Stelle in SortedTail ein.

```
insertionsort([], []).
insertionsort([X|Tail], SortedList) :-
    insertionsort(Tail, SortedTail),
    insert(X, SortedTail, SortedList).

% Wenn diese Regel angewendet wird, darf die
% nächste Regel NICHT angewendet werden. Roter Cut!
insert(X, [Y|Sorted], [Y|Sorted2]) :-
    X > Y, !,
    insert(X, Sorted, Sorted2).
insert(X, Sorted, [X|Sorted]).
```

Idee: Sortiere eine Liste L wie folgt:

- Wähle das erste Element X der Liste L als Pivot-Element.
- Teile mittels `split` die Restliste auf in eine Liste mit kleineren Werten `Small` und eine Liste mit größeren Werten `Big` als X.
- Sortiere `Small` rekursiv zu `SortedSmall`.
- Sortiere `Big` rekursiv zu `SortedBig`.
- Füge die Listen mittels `conc` zusammen zur sortierten Liste `SortedList`.

```
quicksort([], []).  
quicksort([X|Tail], SortedList) :-  
    split(X, Tail, Small, Big),  
    quicksort(Small, SortedSmall),  
    quicksort(Big, SortedBig),  
    conc(SortedSmall, [X|SortedBig], SortedList).
```

Quicksort

```
%%% helper functions for quicksort
split(X, [], [], []).

split(X, [Y|Tail], [Y|SmallItems], BigItems) :-
    X > Y, !,          % Roter Cut!
    split(X, Tail, SmallItems, BigItems).

split(X, [Y|Tail], SmallItems, [Y|BigItems]) :-
    split(X, Tail, SmallItems, BigItems).

conc([], L, L).
conc([X|L1], L2, [X|L3]) :- conc(L1, L2, L3).
```

Übersicht

- 1 Übersicht
- 2 Geschichte und Anwendungen
- 3 Wissensrepräsentation
- 4 Zustandsraumsuche
- 5 Aussagenlogik
- 6 Prädikatenlogik
- 7 Prolog

- Allgemeines
- Erste Schritte
- Arithmetik
- Listen
- Backtracking
- Sortieren
- **Input/Output**
- Zahlenrätsel
- Kannibalen und Missionare
- 8-Damen-Problem
- Schiebepuzzle
- A^* -Algorithmus

In Prolog gibt es build-in predicates zur Interaktion mit dem Anwender:

- `write(X)` gibt den Inhalt des Terms X auf dem Bildschirm aus.
 - `nl` steht für new line.
 - `tab(N)` fügt N Leerzeichen in die Ausgabe ein.
- `read(X)` liest den nächsten Term von der Tastatur und belegt X mit dem gelesenen Wert.
Die Eingabe muss mit einem Punkt abgeschlossen werden.

Beispiel:

```
cube :-  
    write('next value, please: ' ),  
    read(N),  
    C is N*N*N,  
    write(C).
```

Übung 75. Schreiben Sie ein Prädikat `writelst(L)`, das die einzelnen Listen einer Liste von Listen `L` jeweils in einer Zeile ausgibt.

Ausgabe von `writelst([[1,2,3], [3,4,5,6]])`:

1,2,3

3,4,5,6

Übung 76. Schreiben Sie ein Prädikat `bars(L)`, das zu jeder Zahl der Liste jeweils eine Zeile mit entsprechend vielen Sternchen ausgibt.

Ausgabe von `bars([3,6,5])`:

Dateioperationen:

- **tell(File)** leitet die Ausgabe der Prädikate `write`, `put`, `nl` usw. in die Datei `File` um.
- **told** beendet die Umleitung und bewirkt, dass spätere Ausgaben wieder auf dem Bildschirm erscheinen.
- **telling(File)** gibt an, in welche Datei die Ausgabe zur Zeit erfolgt, dabei steht `user` für den Bildschirm.

```
| ?- telling(Anfang),
  tell('datei.txt'),      % öffnen der Datei
  telling(Mitte),
  write('Hallo, '), nl,   % erste Zeile schreiben
  write('Welt!'), nl,      % zweite Zeile schreiben
  told,                   % schließen der Datei
  telling(Ende).
```

Dateioperationen:

- `see(File)` nimmt die Eingabe für die Prädikate `read`, `get` usw. aus der Datei `File`.
- `seen` beendet die Umleitung und bewirkt, dass spätere Eingaben wieder vom Benutzer abgefragt werden.
- `seeing(File)` gibt an, aus welcher Datei die Eingabe zur Zeit genommen wird, dabei steht `user` für die Tastatur.

```
| ?- seeing(Anfang),
  see('datei.txt'),      % öffnen der Datei
  seeing(Mitte),
  get0(X), put(X),      % erstes Zeichen lesen
  get0(Y), put(Y),      % zweites Zeichen lesen
  seen,                  % schließen der Datei
  seeing(Ende).
```

Das Prädikat `read` kann nur dann zum Lesen verwendet werden, wenn Terme gelesen werden, also bspw. Zahlen, Fakten oder Regeln, die allesamt mit einem Punkt abgeschlossen sind.

```
test :-  
    tell('datei.txt'),      % öffnen der Datei  
    write('sunshine.'), nl,  
    write('raining.'), nl,  
    write('funny :- sunshine, raining.'), nl,  
    write('nice :- sunshine, \\\+raining.'),  
    told.                  % schließen der Datei
```

In GNU-Prolog wird `not` als `\+` dargestellt und muss innerhalb einer Zeichenkette natürlich maskiert werden.

Input/Output

Die in einer Datei abgelegten Fakten und Regeln können wie folgt eingelesen und der Datenbasis hinzugefügt werden:

```
add_to_database(File) :-  
    see(File),          /* open file */  
    repeat,  
    read(Data),         /* read from File */  
    process(Data),  
    seen,               /* close File */  
    !.                  /* stop reading */  
  
process(end_of_file) :- !.  
process(Data) :- asserta(Data), nl, fail.
```

Das Prädikat `repeat` ist bei jeder Auswertung wahr und kann verwendet werden, um Schleifen zu programmieren.

1 Übersicht

- Allgemeines

2 Geschichte und Anwendungen

- Erste Schritte

3 Wissensrepräsentation

- Arithmetik

4 Zustandsraumsuche

- Listen

5 Aussagenlogik

- Backtracking

6 Prädikatenlogik

- Sortieren

7 Prolog

- Input/Output

• Zahlenrätsel

- Kannibalen und Missionare

- 8-Damen-Problem

- Schiebepuzzle

- A^* -Algorithmus

Zahlenrätsel

Wir wollen zunächst ein Rätsel der folgenden Form lösen:

$$\begin{array}{r} & & & \text{MEHR} \\ \text{SEND} & \text{AAL} & \text{BILL} & + \text{MATHE} & \text{GERALD} \\ + \text{MORE} & + \text{AAL} & + \text{IRMA} & + \text{MACHT} & + \text{DONALD} \\ \hline \text{MONEY} & \text{FANG} & \text{LIEBE} & \text{FREUDE} & \text{ROBERT} \end{array}$$

Eine naive Implementierung ohne Listen könnte zunächst die einzelnen Ziffern definieren:

```
digit(1).          digit(6).  
digit(2).          digit(7).  
digit(3).          digit(8).  
digit(4).          digit(9).  
digit(5).          digit(0).
```

Zahlenrätsel

Die einzelnen Ziffern müssen paarweise verschieden sein, die ersten Ziffern müssen ungleich 0 sein.

```
solve :- % SEND + MORE = MONEY
    digit(S), S\=0,
    digit(E), E\=S,
    digit(N), N\=E, N\=S,
    digit(D), D\=N, D\=E, D\=S,
    digit(M), M\=D, M\=N, M\=E, M\=S, M\=0,
    digit(O), O\=M, O\=D, O\=N, O\=E, O\=S,
    digit(R), R\=O, R\=M, R\=D, R\=N, R\=E, R\=S,
    digit(Y), Y\=R, Y\=O, Y\=M, Y\=D, Y\=N, Y\=E, Y\=S,
    sum(S,E,N,D,M,O,R,Y),
    write('S = '), write(S), nl,
    ....
    write('Y = '), write(Y), nl.
```

Abschließend müssen wir noch prüfen, ob die gegebene Bedingung
 $SEND + MORE = MONEY$ ist:

```
sum(S,E,N,D,M,O,R,Y) :-  
    N1 is 1000*S + 100*E + 10*N + D,  
    N2 is 1000*M + 100*O + 10*R + E,  
    N3 is 10000*M + 1000*O + 100*N + 10*E + Y,  
    N3 =:= N1 + N2.
```

Fragen:

- Wie können wir die Laufzeit des Programms verbessern?
- Können wir Listen zur Lösung des Problems nutzen, um das Programm kürzer zu gestalten?

Naives Generate-And-Test-Verfahren:

- Erzeuge eine Permutation für die Belegung der Variablen,

```
gen(S,E,N,D,M,O,R,Y) :-  
    permutation([S,E,N,D,M,O,R,Y,_,_],  
                [0,1,2,3,4,5,6,7,8,9]).
```

- teste, ob die gegebene Gleichung für die Belegung erfüllt ist

```
gl(S,E,N,D,M,O,R,Y) :- M \= 0, S \= 0,  
    (S*1000 + E*100 + N*10 + D) +  
    (M*1000 + O*100 + R*10 + E) =:=  
    (M*10000 + O*1000 + N*100 + E*10 + Y).
```

- und gib die Belegung aus.

```
solve :- gen(S,E,N,D,M,O,R,Y),  
        gl(S,E,N,D,M,O,R,Y),  
        write('S = '), write(S), nl,  
        write('E = '), write(E), nl, ....
```

Zahlenrätsel

Wir können es natürlich auch einmal mit dem Einsatz von Wissen versuchen! Hier können wir Wissen über die Addition einbringen:

$$\begin{array}{r} \begin{array}{r} S \quad E \quad N \quad D \\ + \quad M \quad O \quad R \quad E \\ + \quad C3 \quad C2 \quad C1 \\ \hline \end{array} & \begin{array}{l} 10 * C1 + Y =:= D + E \\ 10 * C2 + E =:= N + R + C1 \\ 10 * C3 + N =:= E + O + C2 \\ 10 * M + O =:= S + M + C3 \\ M = 1 \quad (\text{Übertrag}) \end{array} \end{array}$$

Wir formen die obigen Gleichungen um und prüfen nach jeder Belegung einer Variablen, ob die Teilbelegung noch richtig ist:

```
solve :-  
    M = 1,                                % M muss 1 sein  
    L = [2,3,4,5,6,7,8,9,0],                % restliche Ziffern  
    select(S, L, L1),                      % wähle Ziffer für S  
    S > 0,                                 % S muss ungleich 0 sein
```

Zahlenrätsel

```
(C3 = 0; C3 = 1),          % Übertrag ist 0 oder 1
0 is S + M + C3 - 10*M,
select(0, L1, L2),         % 0 ist jetzt eindeutig
                           % entferne 0 aus Rest

select(E, L2, L3),          % wähle Ziffer für E
(C2 = 0; C2 = 1),          % Übertrag ist 0 oder 1
N is E + 0 + C2 - 10*C3,
select(N, L3, L4),          % N ist jetzt eindeutig
                           % entferne N aus Rest

(C1 = 0; C1 = 1),          % Übertrag ist 0 oder 1
R is E + 10*C2 - N - C1,
select(R, L4, L5),          % R ist jetzt eindeutig
                           % entferne R aus Rest
```

```
select(D, L5, L6),           % wähle Ziffer für D
Y is D + E - 10*C1,          % Y ist jetzt eindeutig
select(Y, L6, _),            % entferne Y aus Rest

% und dann noch die Ausgabe
write('S = '), write(S), nl,
write('E = '), write(E), nl,
.....
write('Y = '), write(Y), nl.
```

Laufzeitvergleich?

Wir wollen nun ein Programm schreiben, das obige Idee aufgreift, aber Zahlenrätsel mittels Listen löst.

Wenn wir zwei Zahlen addieren, gehen wir spaltenweise von rechts nach links vor. In einer Spalte addieren wir einen Übertrag C_1 von rechts und zwei Ziffern D_1 und D_2 . Wir erhalten als Ergebnis eine Ziffer D und einen Übertrag C nach links.

$$\begin{array}{r} \dots D_1 \dots \\ \dots D_2 \dots \\ C_1 \quad 0 \\ \hline 0 \quad C \\ \dots D \dots \end{array}$$

Das Carry-Bit in der rechten Spalte ist 0, ebenso darf links vom Ergebnis kein Übertrag-Bit auftreten. Außerdem gilt:

- $D = (D_1 + D_2 + C_1) \bmod 10$
- $C = (D_1 + D_2 + C_1) \div 10$

Wir definieren ein Prädikat `sum(N1, N2, N)`, das die zwei Zahlen N_1 und N_2 , repräsentiert als Liste, addiert und das Ergebnis als Liste N speichert: `sum([0,A,A,L], [0,A,A,L], [F,A,N,G]).`

Das verwendete Prädikat `sum1(N1,N2,N,C1,C2,Digs1,Digs2)` wertet zusätzliche Informationen aus:

- `C1`: Übertrag-Bit vor der Summation
- `C2`: Übertrag-Bit nach der Summation
- `Digs1`: Menge der verfügbaren Ziffern vor der Summation
- `Digs2`: Menge der verbleibenden Ziffern nach der Summation

```
sum(N1, N2, N) :-  
    sum1(N1, N2, N, 0, 0, [0,1,2,3,4,5,6,7,8,9], _).  
  
sum1([], [], [], 0, 0, Digits, Digits).  
sum1([D1|N1], [D2|N2], [D|N], C1, C2, Digs1, Digs2) :-  
    sum1(N1, N2, N, C1, C2, Digs1, Digs2),  
    digitsum(D1, D2, C2, D, C, Digs2, Digs).
```

Das Prädikat `digitsum(D1,D2,C1,D,C,Digs1,Digs)`

- wählt aus den noch verfügbaren Ziffern in `Digs1` die Ziffern `D1`, `D2` und `D` aus, so dass nach der Summation der Spalte noch die Ziffern in `Digs` zur Verfügung stehen.
- berechnet den Wert `D = (D1+D2+C1) mod 10` sowie den Wert `C = (D1+D2+C1) div 10`.

```
digitsum(D1, D2, C1, D, C, Digs1, Digs) :-  
    del(D1, Digs1, Digs2),  
    del(D2, Digs2, Digs3),  
    del(D, Digs3, Digs),  
    S is D1 + D2 + C1,  
    D is S mod 10,  
    C is S // 10.
```

Wir müssen darauf achten, dass eine bereits instanzierte Variable D1, D2 oder D nicht nochmals aus der Liste Digs1 entfernt wird.

```
% do nothing if A is already instantiated
del(A, L, L) :- nonvar(A), !.
del(A, [A|L], L).
del(A, [B|L], [B|L1]) :- del(A, L, L1).

puzzle1([0,S,E,N,D], [0,M,O,R,E], [M,O,N,E,Y]). 
puzzle2([0,B,I,L,L], [0,I,R,M,A], [L,I,E,B,E]). 
puzzle3([D,O,N,A,L,D], [G,E,R,A,L,D], [R,O,B,E,R,T]). 
puzzle4([0,A,A,L], [0,A,A,L], [F,A,N,G]).
```

Aufrufbeispiel: `puzzle1(N1,N2,N3), sum(N1,N2,N3).`

Zahlenrätsel

Es gibt natürlich auch kompliziertere Zahlenrätsel:

$$\begin{array}{rcl} ABB & - & CD = EED \\ - & - & * \\ FD & + & EF = CE \\ = & = & = \\ EGD & * & FH = \text{????} \end{array}$$

$$\begin{array}{rcl} ACE & + & DAC = JFD \\ - & + & - \\ AAA & - & HFC = GI \\ = & = & = \\ AH & + & III = JBJ \end{array}$$

Ein naives Generate-And-Test-Verfahren testet einfach wieder alle möglichen Belegungen:

```
gen(A,B,C,D,E,F,G,H) :-  
    permutation([A,B,C,D,E,F,G,H,_,_],  
                [0,1,2,3,4,5,6,7,8,9]).
```

Zahlenrätsel

Anschließend testen wir, ob alle Gleichungen erfüllt sind:

```
gl1(A,B,C,D,E) :- (E*100 + E*10 + D) =:=  
    ((A*100 + B*10 + B) - (C*10 + D)).  
gl2(C,D,E,F) :- (C*10 + E) =:=  
    ((F*10 + D) + (E*10 + F)).  
gl3(A,B,D,E,F,G) :- (E*100 + G*10 + D) =:=  
    ((A*100 + B*10 + B) - (F*10 + D)).  
gl4(C,D,E,F,H) :- (F*10 + H) =:=  
    ((C*10 + D) - (E*10 + F)).  
  
gl5(C,D,E,F,G,H,X) :-  
    ((E*100 + E*10 + D) * (C*10 + E)) =:=  
    ((E*100 + G*10 + D) * (F*10 + H)),  
    X is ((E*100 + G*10 + D) * (F*10 + H)).
```

Und nun alles zusammen packen:

```
solve :- gen(A,B,C,D,E,F,G,H),
         gl1(A,B,C,D,E),
         gl2(C,D,E,F),
         gl3(A,B,D,E,F,G),
         gl4(C,D,E,F,H),
         gl5(C,D,E,F,G,H,X),
         write('A = '), write(A), nl,
         write('B = '), write(B), nl,
         ....
         write('H = '), write(H), nl,
         write('X = '), write(X).
```

1 Übersicht

- Allgemeines
- Erste Schritte
- Arithmetik
- Listen
- Backtracking
- Sortieren
- Input/Output
- Zahlenrätsel
- **Kannibalen und Missionare**
- 8-Damen-Problem
- Schiebepuzzle
- A^* -Algorithmus

4 Zustandsraumsuche

5 Aussagenlogik

6 Prädikatenlogik

7 Prolog

Erinnern wir uns:

- 3 Missionare und 3 Kannibalen wollen einen Fluss überqueren.
- Es steht nur ein Ruderboot für die Überfahrt zur Verfügung.
- Das Boot kann maximal 2 Personen aufnehmen.
- Es dürfen nie mehr Kannibalen als Missionare an einem Ort sein, sonst gibt es ein großes Fressen.

Zunächst definieren wir einen gültigen Zustand:

```
% keine Missionare --> beliebig viele Kannibalen
zust( 0, Kl, _, _, Kr) :- Kl >= 0, Kr >= 0.
zust( _, Kl, _, 0, Kr) :- Kl >= 0, Kr >= 0.

% sonst: Anzahl Missionare >= Anzahl Kannibalen
zust(Ml, Kl, _, Mr, Kr) :- Ml >= Kl, Mr >= Kr,
                           Kl >= 0, Kr >= 0.
```

Dann definieren wir die Überfahrten vom linken zum rechten Ufer:

Kannibalen und Missionare

```
% 1 Kannibale von Links nach Rechts
```

```
zug(n(Ml,Kl,'L',Mr,Kr), n(Ml,Kl2,'R',Mr,Kr2)) :-  
    Kl2 is Kl - 1,  
    Kr2 is Kr + 1,  
    zust(Ml,Kl2,'R',Mr,Kr2).
```

```
% 2 Kannibalen von Links nach Rechts
```

```
zug(n(Ml,Kl,'L',Mr,Kr), n(Ml,Kl2,'R',Mr,Kr2)) :-  
    Kl2 is Kl - 2,  
    Kr2 is Kr + 2,  
    zust(Ml,Kl2,'R',Mr,Kr2).
```

```
% 1 Kannibale, 1 Missionar von Links nach Rechts
```

```
zug(n(Ml,Kl,'L',Mr,Kr), n(Ml2,Kl2,'R',Mr2,Kr2)) :-  
    Ml2 is Ml - 1,  
    Kl2 is Kl - 1,  
    Mr2 is Mr + 1,  
    Kr2 is Kr + 1,  
    zust(Ml2,Kl2,'R',Mr2,Kr2).
```

```
% 1 Missionar von Links nach Rechts
```

```
zug(n(Ml,Kl,'L',Mr,Kr), n(Ml2,Kl,'R',Mr2,Kr)) :-  
    Ml2 is Ml - 1,  
    Mr2 is Mr + 1,  
    zust(Ml2,Kl,'R',Mr2,Kr).
```

```
% 2 Missionare von Links nach Rechts
```

```
zug(n(Ml,Kl,'L',Mr,Kr), n(Ml2,Kl,'R',Mr2,Kr)) :-  
    Ml2 is Ml - 2,  
    Mr2 is Mr + 2,  
    zust(Ml2,Kl,'R',Mr2,Kr).
```

Dann definieren wir die Überfahrten vom rechten zum linken Ufer:

Kannibalen und Missionare

```
% 1 Kannibale von Rechts nach Links
```

```
zug(n(Ml,Kl,'R',Mr,Kr), n(Ml,Kl2,'L',Mr,Kr2)) :-  
    Kl2 is Kl + 1,  
    Kr2 is Kr - 1,  
    zust(Ml,Kl2,'L',Mr,Kr2).
```

```
% 2 Kannibalen von Rechts nach Links
```

```
zug(n(Ml,Kl,'R',Mr,Kr), n(Ml,Kl2,'L',Mr,Kr2)) :-  
    Kl2 is Kl + 2,  
    Kr2 is Kr - 2,  
    zust(Ml,Kl2,'L',Mr,Kr2).
```

```
% 1 Kannibale, 1 Missionar von Rechts nach Links
```

```
zug(n(Ml,Kl,'R',Mr,Kr), n(Ml2,Kl2,'L',Mr2,Kr2)) :-  
    Ml2 is Ml + 1,  
    Kl2 is Kl + 1,  
    Mr2 is Mr - 1,  
    Kr2 is Kr - 1,  
    zust(Ml2,Kl2,'L',Mr2,Kr2).
```

```
% 1 Missionar von Rechts nach Links
```

```
zug(n(Ml,Kl,'R',Mr,Kr), n(Ml2,Kl,'L',Mr2,Kr)) :-  
    Ml2 is Ml + 1,  
    Mr2 is Mr - 1,  
    zust(Ml2,Kl,'L',Mr2,Kr).
```

```
% 2 Missionare von Rechts nach Links
```

```
zug(n(Ml,Kl,'R',Mr,Kr), n(Ml2,Kl,'L',Mr2,Kr)) :-  
    Ml2 is Ml + 2,  
    Mr2 is Mr - 2,  
    zust(Ml2,Kl,'L',Mr2,Kr).
```

Nun definieren wir eine Zug-Folge, einen Pfad. Im einfachsten Fall erkennen wir keine doppelten Zustände, sondern beschränken nur die Suchtiefe, um „Endlosschleifen“ zu verhindern.

```
% Abbruch, wenn die Suchtiefe überschritten wurde:  
pfad(n( , , , , , ), n( , , , , , ), Tiefe, _) :-  
    Tiefe > 10, !, fail.
```

Um später einen Pfad ausgeben zu können, merken wir uns die gemachten Züge in einer Liste.

```
% Ein einzelner Zug ist ein zulässiger Pfad:  
pfad(n(M1,K1,P1,M2,K2), n(M3,K3,P3,M4,K4),  
    Tiefe, [n(M3,K3,P3,M4,K4) | []]) :-  
    zug(n(M1,K1,P1,M2,K2), n(M3,K3,P3,M4,K4)).
```

Ein Pfad von A nach B existiert, falls es einen Zug von A nach C gibt und ein Pfad von C nach B existiert. Dabei müssen wir die Tiefe hochzählen:

```
pfad(n(M1,K1,P1,M2,K2), n(M5,K5,P5,M6,K6),  
      Tiefe, [n(M3,K3,P3,M4,K4)|L]) :-  
      T is Tiefe + 1,  
      zug(n(M1,K1,P1,M2,K2), n(M3,K3,P3,M4,K4)),  
      pfade(n(M3,K3,P3,M4,K4), n(M5,K5,P5,M6,K6), T, L).
```

Jetzt müssen wir das Ganze nur noch mit einem einfachen Aufruf versehen:

```
solve :- pfade(n(3,3,'L',0,0), n(0,0,'R',3,3), 0, L),  
        write([n(3,3,'L',0,0)|L]).
```

Können wir auf den Tiefenzähler verzichten?

- Wir werden die bereits untersuchten Zustände, also die bisherige Zugfolge, in einer Liste speichern.
- Vor der Ausführung eines neuen Zugs wird getestet, ob der Knoten in der Liste enthalten ist, also bereits untersucht wurde.
- Auf diese Weise vermeiden wir doppelte Zustände und verhindern „Endlosschleifen“.

Die Liste der bisherigen Züge wird in die Ergebnisliste kopiert, wenn eine Belegung erfolgreich war. Wir führen also zwei Listen:

- Die erste Liste enthält die Zustände, die bereits untersucht wurden. Wir füllen diese Liste beim rekursiven Abstieg.
- Da diese Informationen beim Rekursionsabbau wieder verloren gehen, kopieren wir die Werte am Rekursionsende in eine zweite Liste.

Am Rekursionsende wird die erste Liste in die zweite kopiert:

```
% Abbruch, wenn beide Zustände gleich sind:  
pfad(n(M1,K1,P,M2,K2), n(M1,K1,P,M2,K2), L, L) :- !.
```

Sonst erzeugen wir einen Zug zu einem Zwischenziel,

- testen, ob der neue Zustand (das Zwischenziel) noch nicht in der ersten Liste gespeichert ist,
- hängen den neuen Zustand an die alte Liste an und
- versuchen, einen Pfad vom Zwischenziel zum Ziel zu finden.

```
pfad(n(M1,K1,P1,M2,K2), n(M5,K5,P5,M6,K6), L1, L2) :-  
  zug(n(M1,K1,P1,M2,K2), n(M3,K3,P3,M4,K4)),  
  \+ member(n(M3,K3,P3,M4,K4), L1),  
  append(L1, [n(M3,K3,P3,M4,K4)], L),  
  pfad(n(M3,K3,P3,M4,K4), n(M5,K5,P5,M6,K6), L, L2).
```

1 Übersicht

- Allgemeines
- Erste Schritte
- Arithmetik
- Listen
- Backtracking
- Sortieren
- Input/Output
- Zahlenrätsel
- Kannibalen und Missionare
- **8-Damen-Problem**
- Schiebepuzzle
- A^* -Algorithmus

4 Zustandsraumsuche

5 Aussagenlogik

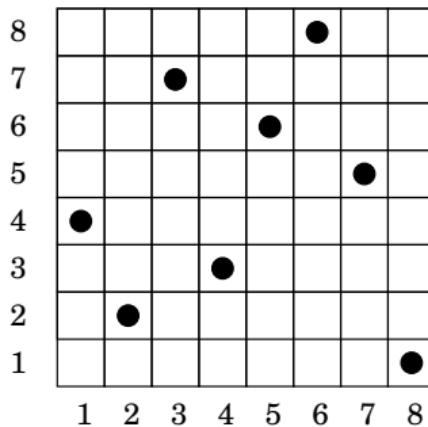
6 Prädikatenlogik

7 Prolog

8-Damen-Problem

Eine Lösung des Problems soll mittels des unären Prädikats `solution(Pos)` dargestellt werden.

Wir stellen den Zustand als Liste von x/y-Koordinaten dar: `[X1/Y1, X2/Y2, X3/Y3, ..., X8/Y8]`.



Damit keine zwei Damen in der selben Spalte stehen, definieren wir ein Template `template([1/Y1, 2/Y2, 3/Y3, ..., 8/Y8]).`

Sammeln wir einige Eigenschaften von gültigen Lösungen:

- Eine leere Liste von Damen ist eine gültige Lösung, da sich keine Damen schlagen.
→ `solution([]).`
- Für eine nicht-leere Liste der Form `[X/Y, Others]` muss gelten:
 - Die Liste `Others` muss eine gültige Lösung sein.
 - `X` und `Y` müssen Integer-Werte zwischen 1 und 8 sein.
 - Die Dame auf Position `X/Y` darf sich mit keiner Dame der Liste `Others` schlagen.

```
→ solution([X/Y | Others]) :-  
    solution(Others),  
    member(Y, [1,2,3,4,5,6,7,8]),  
    noattack(X/Y, Others).
```

8-Damen-Problem

Wie testen wir, ob sich die Dame auf Position X/Y mit denen der Liste Others schlägt, also ob `noattack(Q, QRest)` erfüllt ist?

- Wenn die Liste QRest leer ist, schlagen sich keine Damen.

→ noattack(_, []).

- Falls QRest die Form $[Q1 \mid QRest1]$ hat,

- darf die Dame Q die Dame Q1 nicht schlagen, und
- die Dame Q darf die Damen in QRest1 nicht schlagen.

```
→ noattack(X/Y, [X1/Y1 | Others]) :-
```

$Y = \neq Y1,$ % Zeilen ungleich

$Y_1 - Y = X_1 - X$, % Diagonalen ungleich

$$Y_1 - Y = \sqrt{X - X_1},$$

noattack(X/Y, Others).

Als Abfrage erhalten wir also: `template(S)`, `solution(S)`.

1 Übersicht

- Allgemeines
- Erste Schritte
- Arithmetik
- Listen
- Backtracking
- Sortieren
- Input/Output
- Zahlenrätsel
- Kannibalen und Missionare
- 8-Damen-Problem
- **Schiebepuzzle**
- A^* -Algorithmus

4 Zustandsraumsuche

5 Aussagenlogik

6 Prädikatenlogik

7 Prolog

Zunächst nur eine naive Implementierung:

- Es werden keine Kreise erkannt.
- Vermeide endlose Rekursion durch Tiefenbeschränkung.
- Damit eine Lösung gefunden wird, müssen wir die Tiefe sukzessive erhöhen (iterative deepening).
- Die 0 beschreibt die Position der Lücke.

% Die beiden Endzustände:

```
puzzle(1,2,3,8,0,4,7,6,5,[],Tiefe).  
puzzle(0,1,2,3,4,5,6,7,8,[],Tiefe).
```

% Abbruchbedingung für Tiefensuche:

```
puzzle(X1,X2,X3,Y1,Y2,Y3,Z1,Z2,Z3,L,Tiefe):-  
    Tiefe > 7, !, fail.
```

Schiebepuzzle

```
% Zeile 1, Position links
% Lücke nach rechts schieben
puzzle(0,X2,X3,Y1,Y2,Y3,Z1,Z2,Z3,[X2|L],Tiefe) :-
    T is Tiefe+1,
    puzzle(X2,0,X3,Y1,Y2,Y3,Z1,Z2,Z3,L,T).

% Lücke nach unten schieben
puzzle(0,X2,X3,Y1,Y2,Y3,Z1,Z2,Z3,[Y1|L],Tiefe) :-
    T is Tiefe+1,
    puzzle(Y1,X2,X3,0,Y2,Y3,Z1,Z2,Z3,L,T).
```

Schiebepuzzle

```
% Zeile 1, Position mitte
% Lücke nach links schieben
puzzle(X1,0,X3,Y1,Y2,Y3,Z1,Z2,Z3,[X1|L],Tiefe) :-
    T is Tiefe+1,
    puzzle(0,X1,X3,Y1,Y2,Y3,Z1,Z2,Z3,L,T).

% Lücke nach rechts schieben
puzzle(X1,0,X3,Y1,Y2,Y3,Z1,Z2,Z3,[X3|L],Tiefe) :-
    T is Tiefe+1,
    puzzle(X1,X3,0,Y1,Y2,Y3,Z1,Z2,Z3,L,T).

% Lücke nach unten schieben
puzzle(X1,0,X3,Y1,Y2,Y3,Z1,Z2,Z3,[Y2|L],Tiefe) :-
    T is Tiefe+1,
    puzzle(X1,Y2,X3,Y1,0,Y3,Z1,Z2,Z3,L,T).
```

Schiebepuzzle

```
% Zeile 1, Position rechts
% Lücke nach links schieben
puzzle(X1,X2,0,Y1,Y2,Y3,Z1,Z2,Z3,[X2|L],Tiefe) :-
    T is Tiefe+1,
    puzzle(X1,0,X2,Y1,Y2,Y3,Z1,Z2,Z3,L,T).

% Lücke nach unten schieben
puzzle(X1,X2,0,Y1,Y2,Y3,Z1,Z2,Z3,[Y3|L],Tiefe) :-
    T is Tiefe+1,
    puzzle(X1,X2,Y3,Y1,Y2,0,Z1,Z2,Z3,L,T).
```

Schiebepuzzle

```
% Zeile 2, Position links
% Lücke nach rechts schieben
puzzle(X1,X2,X3,0,Y2,Y3,Z1,Z2,Z3,[Y2|L],Tiefe) :-
    T is Tiefe+1,
    puzzle(X1,X2,X3,Y2,0,Y3,Z1,Z2,Z3,L,T).

% Lücke nach oben schieben
puzzle(X1,X2,X3,0,Y2,Y3,Z1,Z2,Z3,[X1|L],Tiefe) :-
    T is Tiefe+1,
    puzzle(0,X2,X3,X1,Y2,Y3,Z1,Z2,Z3,L,T).

% Lücke nach unten schieben
puzzle(X1,X2,X3,0,Y2,Y3,Z1,Z2,Z3,[Z1|L],Tiefe) :-
    T is Tiefe+1,
    puzzle(X1,X2,X3,Z1,Y2,Y3,0,Z2,Z3,L,T).
```

Schiebepuzzle

```
% Zeile 2, Position mitte
% Lücke nach links schieben
puzzle(X1,X2,X3,Y1,0,Y3,Z1,Z2,Z3,[Y1|L],Tiefe) :-
    T is Tiefe+1,
    puzzle(X1,X2,X3,0,Y1,Y3,Z1,Z2,Z3,L,T).

% Lücke nach rechts schieben
puzzle(X1,X2,X3,Y1,0,Y3,Z1,Z2,Z3,[Y3|L],Tiefe) :-
    T is Tiefe+1,
    puzzle(X1,X2,X3,Y1,Y3,0,Z1,Z2,Z3,L,T).
```

Schiebepuzzle

```
% Zeile 2, Position mitte (Fortsetzung)
% Lücke nach oben schieben
puzzle(X1,X2,X3,Y1,0,Y3,Z1,Z2,Z3,[X2|L],Tiefe) :-
    T is Tiefe+1,
    puzzle(X1,0,X3,Y1,X2,Y3,Z1,Z2,Z3,L,T).

% Lücke nach unten schieben
puzzle(X1,X2,X3,Y1,0,Y3,Z1,Z2,Z3,[Z2|L],Tiefe) :-
    T is Tiefe+1,
    puzzle(X1,X2,X3,Y1,Z2,Y3,Z1,0,Z3,L,T).
```

Schiebepuzzle

```
% Zeile 2, Position rechts
% Lücke nach links schieben
puzzle(X1,X2,X3,Y1,Y2,0,Z1,Z2,Z3,[Y2|L],Tiefe) :-
    T is Tiefe+1,
    puzzle(X1,X2,X3,Y1,0,Y2,Z1,Z2,Z3,L,T).

% Lücke nach oben schieben
puzzle(X1,X2,X3,Y1,Y2,0,Z1,Z2,Z3,[X3|L],Tiefe) :-
    T is Tiefe+1,
    puzzle(X1,X2,0,Y1,Y2,X3,Z1,Z2,Z3,L,T).

% Lücke nach unten schieben
puzzle(X1,X2,X3,Y1,Y2,0,Z1,Z2,Z3,[Z3|L],Tiefe) :-
    T is Tiefe+1,
    puzzle(X1,X2,X3,Y1,Y2,Z3,Z1,Z2,0,L,T).
```

Schiebepuzzle

```
% Zeile 3, Position links
% Lücke nach rechts schieben
puzzle(X1,X2,X3,Y1,Y2,Y3,0,Z2,Z3,[Z2|L],Tiefe) :-
    T is Tiefe+1,
    puzzle(X1,X2,X3,Y1,Y2,Y3,Z2,0,Z3,L,T).

% Lücke nach oben schieben
puzzle(X1,X2,X3,Y1,Y2,Y3,0,Z2,Z3,[Y1|L],Tiefe) :-
    T is Tiefe+1,
    puzzle(X1,X2,X3,0,Y2,Y3,Y1,Z2,Z3,L,T).
```

Schiebepuzzle

```
% Zeile 3, Position mitte
% Lücke nach links schieben
puzzle(X1,X2,X3,Y1,Y2,Y3,Z1,0,Z3,[Z1|L],Tiefe) :-
    T is Tiefe+1,
    puzzle(X1,X2,X3,Y1,Y2,Y3,0,Z1,Z3,L,T).

% Lücke nach rechts schieben
puzzle(X1,X2,X3,Y1,Y2,Y3,Z1,0,Z3,[Z3|L],Tiefe) :-
    T is Tiefe+1,
    puzzle(X1,X2,X3,Y1,Y2,Y3,Z1,Z3,0,L,T).

% Lücke nach oben schieben
puzzle(X1,X2,X3,Y1,Y2,Y3,Z1,0,Z3,[Y2|L],Tiefe) :-
    T is Tiefe+1,
    puzzle(X1,X2,X3,Y1,0,Y3,Z1,Y2,Z3,L,T).
```

Schiebepuzzle

```
% Zeile 3, Position rechts
% Lücke nach links schieben
puzzle(X1,X2,X3,Y1,Y2,Y3,Z1,Z2,0,[Z2|L],Tiefe) :-
    T is Tiefe+1,
    puzzle(X1,X2,X3,Y1,Y2,Y3,Z1,0,Z2,L,T).

% Lücke nach oben schieben
puzzle(X1,X2,X3,Y1,Y2,Y3,Z1,Z2,0,[Y3|L],Tiefe) :-
    T is Tiefe+1,
    puzzle(X1,X2,X3,Y1,Y2,0,Z1,Z2,Y3,L,T).
```

Auch hier können wir, wie beim Kannibalen-Missionare-Problem, die Tiefenbeschränkung ersetzen, indem wir den neuen Zustand daraufhin überprüfen, ob er in der Liste der bereits besuchten Zustände enthalten ist.

Allerdings nützt uns das in diesem Fall gar nichts, da bei der Tiefensuche evtl. sehr ungünstige, d.h. sehr lange Wege gefunden werden und die Suchtiefe die Stack-Größe von Prolog überschreitet:

```
Fatal Error: global stack overflow
```

Daher werden wir den A^* -Algorithmus implementieren, um kürzere, bessere Lösungen zu finden. Das hier vorgestellte Programm ist angelehnt an die Lösung unter:

https://www.cpp.edu/~jrfisher/www/prolog_tutorial/contents.html

1 Übersicht

- Allgemeines
- Erste Schritte
- Arithmetik
- Listen
- Backtracking
- Sortieren
- Input/Output
- Zahlenrätsel
- Kannibalen und Missionare
- 8-Damen-Problem
- Schiebepuzzle
- **A^* -Algorithmus**

4 Zustandsraumsuche

5 Aussagenlogik

6 Prädikatenlogik

7 Prolog

Einen Knoten des Baums stellen wir als Struktur `node(State, Depth, F, [Ancestors])` dar:

- State: repräsentierter Zustand
- Depth: Tiefe des Knotens im Baum, also $g(n)$.
- F: Wert der Bewertungsfunktion $f(n) = g(n) + h(n)$.
- Ancestors: Liste der Vorgänger des Knotens.

Um eine Lösung zu berechnen, rufen wir das Haupt-Prädikat des Programms `solve(Start, Sol)` auf. Dabei beschreibt Start den Startzustand und in Sol wird die Lösung dargestellt:

- Zunächst wird der f -Wert für Start berechnet.
- Anschließend wird mittels `search` ein Weg zum Ziel gesucht. Dabei wird die aktualisierte `OpenList` als Parameter übergeben.
- Schließlich muss die Vorgängerliste umgedreht werden.

```
solve(State, Solution) :-  
    f_function(State, 0, F),  
    search([node(State, 0, F, [])], S),  
    reverse(S, Solution).
```

Das Prädikat `f_function(State,D,F)` berechnet den Wert `F` für den Zustand `State` in Tiefe `D`.

- Dazu wird ein Prädikat `h_function(State,H)` aufgerufen, das wir für jedes Problem spezifisch implementieren müssen.
- Das Prädikat liefert in `H` den Wert der Schätzfunktion `h` vom Zustand `State` aus.

```
f_function(State, D, F) :-  
    h_function(State, H),  
    F is D + H.
```

Die Suche eines Zielknotens mittels `search` benötigt die OpenList:

- Der erste Knoten B wird aus der OpenList entfernt, alle Folgeknoten Children von B werden mittels `expand` bestimmt und mittels `insert_all` in die OpenList eingefügt. Anschließend wird die Suche rekursiv mit der aktualisierten OpenList aufgerufen.
- Die Suche endet, falls ein Ziel gefunden wird. Dazu muss für jedes Problem ein spezifisches Prädikat `goal(State)` bereit gestellt werden, das anzeigt, ob `State` ein gültiges Ziel ist.

```
search([node(State,_,_,Sol)|_], Sol) :- goal(State).  
search([B|Tail],S) :-  
    expand(B,Children),  
    insert_all(Children,Tail,Open),  
    search(Open,S).
```

Wenn ein Knoten `node(State, Depth, F, [A])` expandiert wird, passiert folgendes:

- Bestimme alle Kinder des Knotens.
- Jedes Kind hat Tiefe $Depth + 1$.
- Der F-Wert wird für jedes Kind berechnet.
- Die Vorgänger-Liste A wird vom Kind übernommen und ergänzt.

```
expand(node(State,D,_,S),All_My_Children) :-  
    bagof(node(Child,D1,F,[Move|S]),  
          ( D1 is D+1,  
            move(State,Child,Move),  
            f_function(Child,D1,F)),  
          All_My_Children).
```

Das Einfügen von Knoten in die OpenList erfolgt mittels einer Insertionsort-Variante. Dabei werden doppelte Zustände entfernt, die Einordnung der Elemente erfolgt anhand des f -Wertes.

```
insert_all([F|R],Open1,Open3) :-  
    insert(F,Open1,Open2),  
    insert_all(R,Open2,Open3).  
insert_all([],Open,Open).  
  
insert(B,Open,Open) :- repeat_node(B,Open), ! .  
insert(B,[C|R],[B,C|R]) :- cheaper(B,C), ! .  
insert(B,[B1|R],[B1|S]) :- insert(B,R,S), ! .  
insert(B,[],[B]).  
  
repeat_node(node(P,_,_,_), [node(P,_,_,_)|_]).  
cheaper(node(_,_,F1,_), node(_,_,F2,_)) :- F1 < F2.
```

8-Puzzle: Zunächst die Aufzählung aller möglichen Züge.

```
left( A/0/C/D/E/F/H/I/J , 0/A/C/D/E/F/H/I/J ).  
left( A/B/C/D/0/F/H/I/J , A/B/C/0/D/F/H/I/J ).  
left( A/B/C/D/E/F/H/0/J , A/B/C/D/E/F/0/H/J ).  
left( A/B/0/D/E/F/H/I/J , A/0/B/D/E/F/H/I/J ).  
left( A/B/C/D/E/0/H/I/J , A/B/C/D/0/E/H/I/J ).  
left( A/B/C/D/E/F/H/I/0 , A/B/C/D/E/F/H/0/I ).  
  
up( A/B/C/0/E/F/H/I/J , 0/B/C/A/E/F/H/I/J ).  
up( A/B/C/D/0/F/H/I/J , A/0/C/D/B/F/H/I/J ).  
up( A/B/C/D/E/0/H/I/J , A/B/0/D/E/C/H/I/J ).  
up( A/B/C/D/E/F/0/I/J , A/B/C/0/E/F/D/I/J ).  
up( A/B/C/D/E/F/H/0/J , A/B/C/D/0/F/H/E/J ).  
up( A/B/C/D/E/F/H/I/0 , A/B/C/D/E/0/H/I/F ).
```

A^* -Algorithmus

```
right( A/0/C/D/E/F/H/I/J , A/C/0/D/E/F/H/I/J ).  
right( A/B/C/D/0/F/H/I/J , A/B/C/D/F/0/H/I/J ).  
right( A/B/C/D/E/F/H/0/J , A/B/C/D/E/F/H/J/0 ).  
right( 0/B/C/D/E/F/H/I/J , B/0/C/D/E/F/H/I/J ).  
right( A/B/C/0/E/F/H/I/J , A/B/C/E/0/F/H/I/J ).  
right( A/B/C/D/E/F/0/I/J , A/B/C/D/E/F/I/0/J ).  
  
down( A/B/C/0/E/F/H/I/J , A/B/C/H/E/F/0/I/J ).  
down( A/B/C/D/0/F/H/I/J , A/B/C/D/I/F/H/0/J ).  
down( A/B/C/D/E/0/H/I/J , A/B/C/D/E/J/H/I/0 ).  
down( 0/B/C/D/E/F/H/I/J , D/B/C/0/E/F/H/I/J ).  
down( A/0/C/D/E/F/H/I/J , A/E/C/D/0/F/H/I/J ).  
down( A/B/0/D/E/F/H/I/J , A/B/F/D/E/0/H/I/J ).
```

Nun müssen wir einige, für das 8-Puzzle spezifische Prädikate definieren. Als Schätzer verwenden wir die Manhatten-Distanz:

```
h_function(Puzz,H) :- p_fcn(Puzz,H).  
  
p_fcn(A/B/C/D/E/F/G/H/I, P) :-  
    a(A,Pa), b(B,Pb), c(C,Pc),  
    d(D,Pd), e(E,Pe), f(F,Pf),  
    g(G,Pg), h(H,Ph), i(I,Pi),  
    P is Pa+Pb+Pc+Pd+Pe+Pf+Pg+Ph+Pi.
```

```
a(0,0). a(1,0). a(2,1). a(3,2). a(4,3).  
    a(5,4). a(6,3). a(7,2). a(8,1).  
b(0,0). b(1,1). b(2,0). b(3,1). b(4,2).  
    b(5,3). b(6,2). b(7,3). b(8,2).
```

A^* -Algorithmus

```
c(0,0).  c(1,2).  c(2,1).  c(3,0).  c(4,1).  
        c(5,2).  c(6,3).  c(7,4).  c(8,3).  
d(0,0).  d(1,1).  d(2,2).  d(3,3).  d(4,2).  
        d(5,3).  d(6,2).  d(7,2).  d(8,0).  
e(0,0).  e(1,2).  e(2,1).  e(3,2).  e(4,1).  
        e(5,2).  e(6,1).  e(7,2).  e(8,1).  
f(0,0).  f(1,3).  f(2,2).  f(3,1).  f(4,0).  
        f(5,1).  f(6,2).  f(7,3).  f(8,2).  
g(0,0).  g(1,2).  g(2,3).  g(3,4).  g(4,3).  
        g(5,2).  g(6,2).  g(7,0).  g(8,1).  
h(0,0).  h(1,3).  h(2,3).  h(3,3).  h(4,2).  
        h(5,1).  h(6,0).  h(7,1).  h(8,2).  
i(0,0).  i(1,4).  i(2,3).  i(3,2).  i(4,1).  
        i(5,0).  i(6,1).  i(7,2).  i(8,3).
```

Das Prädikat `expand` des A^* -Algorithmus benötigt das Prädikat `move`, das wir für das 8-Puzzle wie folgt definieren:

```
move(State, Child, l) :- left(State, Child).  
move(State, Child, u) :- up(State, Child).  
move(State, Child, r) :- right(State, Child).  
move(State, Child, d) :- down(State, Child).
```

In der Ergebnisliste, die dem Benutzer des Prolog-Programms angezeigt wird, stehen nur die Werte 'l', 'u', 'r' und 'd'.

Als Letztes müssen wir noch das Ziel-Prädikat definieren:

```
goal(1/2/3/8/0/4/7/6/5).
```

Jetzt können wir eine Lösung zu einem Startzustand berechnen lassen:

```
| ?- solve(1/6/2/7/0/3/5/8/4, S).  
S = [d,l,u,r,u,r,d,d,l,u] ? ;  
S = [d,l,u,r,u,r,d,d,l,u,l,r] ? ;  
S = [d,l,u,d,u,r,u,r,d,d,l,u] ? ;  
S = [d,l,u,r,u,r,d,d,l,u,l,r,l,r] ? ;  
S = [d,l,r,l,u,r,u,r,d,d,l,u] ?  
.....
```

Wir nutzen oben das Systemprädikat `bagof(X, P, L)`:

- Liefert die Liste L, die alle Objekte X enthält, die das Ziel P erfüllen.
- Macht in der Regel nur Sinn, falls X und P gemeinsame Variablen enthalten.
- Beispiel: Klassifizierung von Buchstaben in Vokale und Konsonanten.

```
class(a, vok).      class(d, kon).  
class(b, kon).      class(e, vok).  
class(c, kon).      class(f, kon).
```

Wir können mittels `bagof` eine Liste aller Vokale erstellen lassen:

```
| ?- bagof(Letter, class(Letter, vok), Letters).  
Letters = [a,e]  
yes
```

Weitere Systemprädikate:

- `integer(A)` wird einmal wahr, falls A eine ganze Zahl ist.
- `var(A)` wird einmal wahr, wenn A eine (nicht instantiierte) Variable ist.
- `repeat` wird beliebig oft wahr.
- und viele weitere