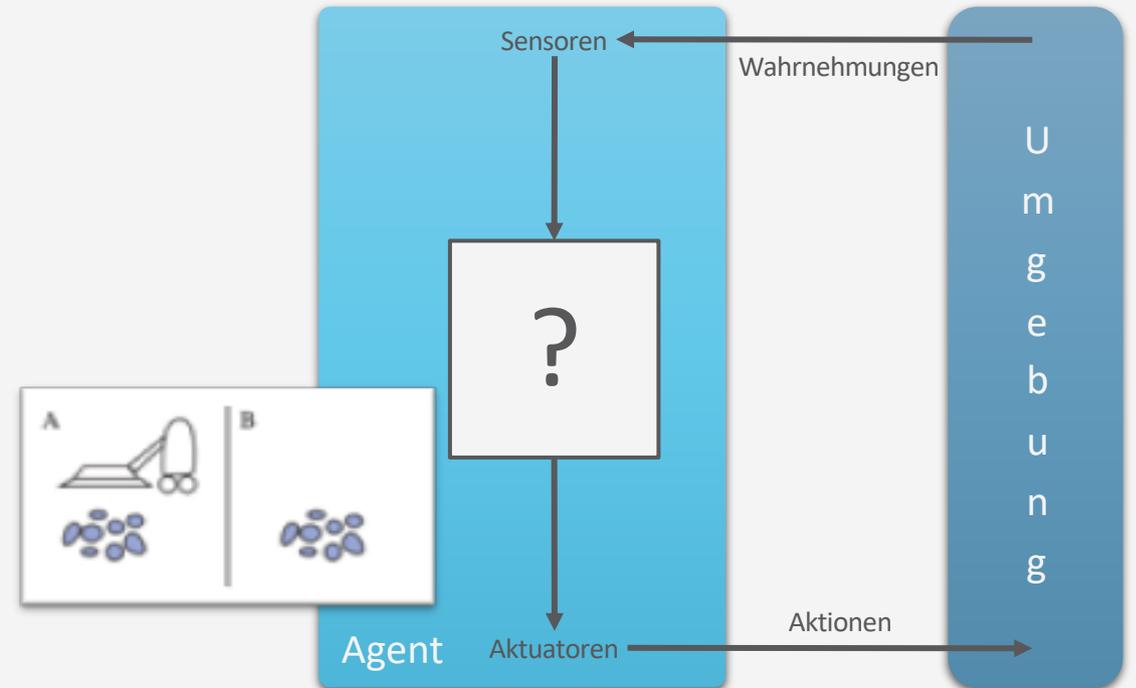


# Künstliche Intelligenz & Agenten

Einführung in die  
Künstliche Intelligenz



# Inhalte

## 1. Künstliche Intelligenz & Agenten

- Agentenabstraktion, Rationalität
- Aufgabenumgebung

## 2. Episodische PGMs

- Gerichtetes Modell: Bayes Netze (BNs)
- Ungerichtete Modelle

## 3. Exakte Inferenz in episodischen PGMs

- Wahrscheinlichkeits- und Zustandsanfragen
- Direkt auf den Modellen, mittels Hilfsstrukturen

## 4. Approximative Inferenz in episodischen PGMs

- Wahrscheinlichkeitsanfragen
- Deterministische, stochastische Algorithmen

## 5. Lernalgorithmen für episodische PGMs

- Bei (nicht) vollständigen Daten, (un)bekannter Struktur

## 6. Sequentielle PGMs und Inferenz

- Dynamische BNs, Hidden-Markov-Modelle
- filtering / prediction / hindsight Anfragen, wahrscheinlichste Zustandssequenz
- Exakter, approximativer Algorithmus

## 7. Entscheidungstheoretische PGMs

- Präferenzen, Nutzenprinzip
- PGMs mit Entscheidungs- und Nutzenknoten
- Berechnung der besten Aktion (Aktionssequenz)

## 8. Abschlussbetrachtungen

# Überblick: 1. Künstliche Intelligenz & Agenten

## A. *Was ist KI?*

- Menschliches und rationales Denken & Handeln

## B. *Agenten*

- Agentenabstraktion
- Eigenschaften

## C. *Aufgabenumgebung*

- PEAS
- Eigenschaften

## D. *Agentenstruktur*

- Reflexiv, modellbasiert, zielbasiert, nutzenbasiert, lernend

# Definitionen Künstlicher Intelligenz

- Alle Ansätze sind verfolgt worden
  - Haben sich gegenseitig unterstützt und behindert
- **Rationalität**
  - Seinen Kenntnissen entsprechend das „Richtige“ machen

Erfolgsbemessung	
Wiedergabetreue menschlicher Leistung	Ideale Leistungsgröße <b>Rationalität</b>
<b>Menschliches Denken</b> „Das spannende, neuartige Unterfangen, Computern das Denken beizubringen, ... Maschinen mit Verstand im wahrsten Sinne des Wortes.“ (Haugeland, 1985) „[Die Automatisierung von] Aktivitäten, die wir dem menschlichen Denken zuordnen, Aktivitäten wie beispielsweise Entscheidungsfindung, Problemlösung, Lernen ...“ (Bellman, 1978)	<b>Rationales Denken</b> „Die Studie mentaler Fähigkeiten durch die Nutzung programmierter Modelle.“ (Charniak und McDermott, 1985) „Das Studium derjenigen mathematischen Formalismen, die es ermöglichen, wahrzunehmen, logisch zu schließen und zu agieren.“ (Winston, 1992)
<b>Menschliches Handeln</b> „Die Kunst, Maschinen zu schaffen, die Funktionen erfüllen, die, werden sie von Menschen ausgeführt, der Intelligenz bedürfen.“ (Kurzweil, 1990) „Das Studium des Problems, Computer dazu zu bringen, Dinge zu tun, bei denen ihnen momentan der Mensch noch überlegen ist.“ (Rich und Knight, 1991)	<b>Rationales Handeln</b> „Computerintelligenz ist die Studie des Entwurfs intelligenter Agenten.“ (Poole et al., 1998) „KI ... beschäftigt sich mit intelligentem Verhalten in künstlichen Maschinen.“ (Nilsson, 1998)

Denkprozesse,  
logisches  
Schließen

Verhalten

# Menschliches Handeln

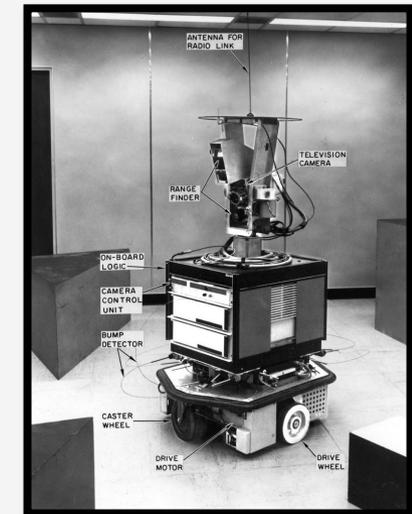
- **Turing-Test** (Turing, 1950)
  - Computer besteht Test, wenn ein Mensch, der einige schriftliche Fragen stellt, nicht erkennen kann, ob die schriftlichen Antworten von einem Menschen stammen oder nicht
  - Beispiel: *Eliza*, Programm zur oberflächlichen Simulation eines Psychotherapeuten
  - Siehe auch Kap. 26, AIMA, inklusive Diskussion, ob das Bestehen des Tests Intelligenz nachweist
    - Bzgl. Eliza: Menschen tendieren dazu bei Aspekten der emotionalen / sozialen Intelligenz eher Schlüsse zu ziehen
    - Cf. Roboter *Shakey*: Keiner nimmt an, dass Shakey Fußball spielen kann
  - **Totaler Turing-Test**: Videosignal um wahrnehmungsorientierte Fähigkeiten zu testen, Objekte weiterzugeben

```

Welcome to
EEEEEE LL   IIII ZZZZZZ  AAAAA
EE   LL   II   ZZ   AA  AA
EEEEEE LL   II   ZZZ  AAAAAA
EE   LL   II   ZZ   AA  AA
EEEEEE LLLLL IIII ZZZZZZ  AA  AA

Eliza is a mock Rogerian psychotherapist.
The original program was described by Joseph Weizenbaum in 1966.
This implementation by Norbert Landsteiner 2005.

ELIZA: Is something troubling you ?
YOU:  Men are all alike.
ELIZA: What is the connection, do you suppose ?
YOU:  They're always bugging us about something or other.
ELIZA: Can you think of a specific example ?
YOU:  Well, my boyfriend made me come here.
ELIZA: Is it important to you that your boyfriend made you come here ?
YOU:  He says I'm depressed much of the time.
ELIZA: I am sorry to hear that you are depressed.
YOU:  It's true. I am unhappy.
ELIZA: Can you explain what made you unhappy ?
YOU:  █
  
```



# Menschliches Handeln

- Zu lösende Teilprobleme des Turing-Tests
  - *Verarbeitung natürlicher Sprache*
    - Kommunikation
  - *Wissensrepräsentation*
    - Wissen und Beobachtungen speichern
  - *Automatisches logisches Schließen*
    - Fragen beantworten, Schlüsse ziehen
  - *Maschinlernen*
    - An Umstände anpassen, Muster erkennen, extrapolieren
  - Totaler Turing-Test
    - *Computervision*: Objekte wahrnehmen
    - *Robotik*: Objekte manipulieren, bewegen

Der Turing-Test deckt einen Großteil der Disziplinen ab, die heute unter KI fallen.

- Aber:
  - wenig Aufwand in der Forschung ausgerichtet darauf Test zu bestehen
- Stattdessen:
  - Zugrundeliegende Prinzipien verstehen

# Definitionen Künstlicher Intelligenz

- Alle Ansätze sind verfolgt worden
  - Haben sich gegenseitig unterstützt und behindert
- **Rationalität**
  - Seinen Kenntnissen entsprechend das „Richtige“ machen

Erfolgsbemessung	
Wiedergabetreue menschlicher Leistung	Ideale Leistungsgröße <b>Rationalität</b>
<p><b>Menschliches Denken</b></p> <p>„Das spannende, neuartige Unterfangen, Computern das Denken beizubringen, ... Maschinen mit Verstand im wahrsten Sinne des Wortes.“ (Haugeland, 1985)</p> <p>„[Die Automatisierung von] Aktivitäten, die wir dem menschlichen Denken zuordnen, Aktivitäten wie beispielsweise Entscheidungsfindung, Problemlösung, Lernen ...“ (Bellman, 1978)</p>	<p><b>Rationales Denken</b></p> <p>„Die Studie mentaler Fähigkeiten durch die Nutzung programmiertechnischer Modelle.“ (Charniak und McDermott, 1985)</p> <p>„Das Studium derjenigen mathematischen Formalismen, die es ermöglichen, wahrzunehmen, logisch zu schließen und zu agieren.“ (Winston, 1992)</p>
<p><b>Menschliches Handeln</b></p> <p>„Die Kunst, Maschinen zu schaffen, die Funktionen erfüllen, die, werden sie von Menschen ausgeführt, der Intelligenz bedürfen.“ (Kurzweil, 1990)</p> <p>„Das Studium des Problems, Computer dazu zu bringen, Dinge zu tun, bei denen ihnen momentan der Mensch noch überlegen ist.“ (Rich und Knight, 1991)</p>	<p><b>Rationales Handeln</b></p> <p>„Computerintelligenz ist die Studie des Entwurfs intelligenter Agenten.“ (Poole et al., 1998)</p> <p>„KI ... beschäftigt sich mit intelligentem Verhalten in künstlichen Maschinen.“ (Nilsson, 1998)</p>

Denkprozesse,  
logisches  
Schließen

Verhalten

# Menschliches Denken

- Ein „Programm denkt wie ein Mensch“
  - Festlegen, wie Menschen denken → Arbeitsweise des menschlichen Gehirns
  - Wenn Theorie über Verstand vorhanden, dann als Computerprogramm ausdrücken
    - Wenn Eingaben und Ausgaben menschlichem Verhalten entsprechen, Indiz dafür, dass einige der Mechanismen des Programms auch im Menschen funktionieren können
- Ansatz komplementär zur KI: *Kognitionswissenschaft*
  - Interdisziplinär:
    - Computermodelle aus der KI
    - Experimentelle Techniken aus der Psychologie
  - Ziel:  
Exakte und überprüfbare Theorien zur Arbeitsweise des menschlichen Verstandes konstruieren

# Definitionen Künstlicher Intelligenz

- Alle Ansätze sind verfolgt worden
  - Haben sich gegenseitig unterstützt und behindert
- **Rationalität**
  - Seinen Kenntnissen entsprechend das „Richtige“ machen

Erfolgsbemessung	
Wiedergabetreue menschlicher Leistung	Ideale Leistungsgröße <b>Rationalität</b>
<b>Menschliches Denken</b>	<b>Rationales Denken</b>
„Das spannende, neuartige Unterfangen, Computern das Denken beizubringen, ... Maschinen mit Verstand im wahrsten Sinne des Wortes.“ (Haugeland, 1985) „[Die Automatisierung von] Aktivitäten, die wir dem menschlichen Denken zuordnen, Aktivitäten wie beispielsweise Entscheidungsfindung, Problemlösung, Lernen ...“ (Bellman, 1978)	„Die Studie mentaler Fähigkeiten durch die Nutzung programmiertechnischer Modelle.“ (Charniak und McDermott, 1985) „Das Studium derjenigen mathematischen Formalismen, die es ermöglichen, wahrzunehmen, logisch zu schließen und zu agieren.“ (Winston, 1992)
<b>Menschliches Handeln</b>	<b>Rationales Handeln</b>
„Die Kunst, Maschinen zu schaffen, die Funktionen erfüllen, die, werden sie von Menschen ausgeführt, der Intelligenz bedürfen.“ (Kurzweil, 1990) „Das Studium des Problems, Computer dazu zu bringen, Dinge zu tun, bei denen ihnen momentan der Mensch noch überlegen ist.“ (Rich und Knight, 1991)	„Computerintelligenz ist die Studie des Entwurfs intelligenter Agenten.“ (Poole et al., 1998) „KI ... beschäftigt sich mit intelligentem Verhalten in künstlichen Maschinen.“ (Nilsson, 1998)

Denkprozesse,  
logisches  
Schließen

Verhalten

# Rationales Denken

- Denken formalisieren → Regeln
  - Unwiderlegbare Prozesse für logisches Schließen
- Gebiet der *Logik*
  - Exakte Notation für Aussagen zu Dingen in der Welt und den Beziehungen zwischen Ihnen
  - Programme / Algorithmen um jedes lösbares Problem, das in logischer Notation geschrieben ist, lösen zu können
  - Hindernisse:
    - Formloses Wissen
      - Unstrukturierte Daten
      - Unsicherheit
    - Jedes Problem auch praktisch lösen zu können
      - Beschränkte Ressourcen

Hindernisse gelten im Prinzip für jeden Versuch logisches Schließen in irgendeiner Form zu realisieren

- Zuerst in der Logik formuliert

# Definitionen Künstlicher Intelligenz

- Alle Ansätze sind verfolgt worden
  - Haben sich gegenseitig unterstützt und behindert
- **Rationalität**
  - Seinen Kenntnissen entsprechend das „Richtige“ machen

Erfolgsbemessung	
Wiedergabetreue menschlicher Leistung	Ideale Leistungsgröße <b>Rationalität</b>
<b>Menschliches Denken</b> „Das spannende, neuartige Unterfangen, Computern das Denken beizubringen, ... Maschinen mit Verstand im wahrsten Sinne des Wortes.“ (Haugeland, 1985) „[Die Automatisierung von] Aktivitäten, die wir dem menschlichen Denken zuordnen, Aktivitäten wie beispielsweise Entscheidungsfindung, Problemlösung, Lernen ...“ (Bellman, 1978)	<b>Rationales Denken</b> „Die Studie mentaler Fähigkeiten durch die Nutzung programmierter Modelle.“ (Charniak und McDermott, 1985) „Das Studium derjenigen mathematischen Formalismen, die es ermöglichen, wahrzunehmen, logisch zu schließen und zu agieren.“ (Winston, 1992)
<b>Menschliches Handeln</b> „Die Kunst, Maschinen zu schaffen, die Funktionen erfüllen, die, werden sie von Menschen ausgeführt, der Intelligenz bedürfen.“ (Kurzweil, 1990) „Das Studium des Problems, Computer dazu zu bringen, Dinge zu tun, bei denen ihnen momentan der Mensch noch überlegen ist.“ (Rich und Knight, 1991)	<b>Rationales Handeln</b> „Computerintelligenz ist die Studie des Entwurfs intelligenter Agenten.“ (Poole et al., 1998) „KI ... beschäftigt sich mit intelligentem Verhalten in künstlichen Maschinen.“ (Nilsson, 1998)

Denkprozesse,  
logisches  
Schließen

Verhalten

## Rationales Handeln

- Ansatz des rationalen Agenten
- **Agent** = Etwas, das agiert
  - Autonom operieren
  - Umgebung wahrnehmen
  - Über längeren Zeitraum beständig sein
  - Sich an Änderungen anpassen
  - Ziele erzeugen und verfolgen
- **Rationaler Agent**
  - Verhalten, welches das beste Ergebnis, bzw. im Fall von Unsicherheit, das beste zu erwartende Ergebnis liefert
  - Kann auch rationales Denken und menschliches Handeln beinhalten, aber *allgemeiner*

*Vorteil:* Rationalität erlaubt mathematische Definition

- Besser geeignet, überprüfbare Agentenentwürfe zu erzeugen

→ *Fokus der Vorlesung:*

- Allgemeine Prinzipien rationaler Agenten
- Komponenten, aus denen Agenten erzeugt werden können, speziell PGMs

## Zwischenzusammenfassung

- Künstliche Intelligenz unter dem Aspekt
  - Menschliches Handeln
    - Turing-Test
    - Teilprobleme: Sprachverarbeitung, Wissensrepräsentation, Schließen, Maschinenlernen, Computervision, Robotik
  - Menschliches Denken
    - Kognitionswissenschaften als interdisziplinäres Gebiet zwischen KI und Psychologie
  - Rationales Denken
    - Logik für Wissensrepräsentation und korrektes Schlussfolgern
  - Rationales Handeln
    - Rationaler Agent als Verallgemeinerung des rationalen Denkens mit mathematischer Definition von Rationalität als formales Kriterium
    - Greift Teilprobleme, die der Turing-Test identifiziert, wieder auf

# Überblick: 1. Künstliche Intelligenz & Agenten

## A. *Was ist KI?*

- Menschliches und rationales Denken & Handeln

## B. **Agenten**

- Agentenabstraktion
- Eigenschaften

## C. *Aufgabenumgebung*

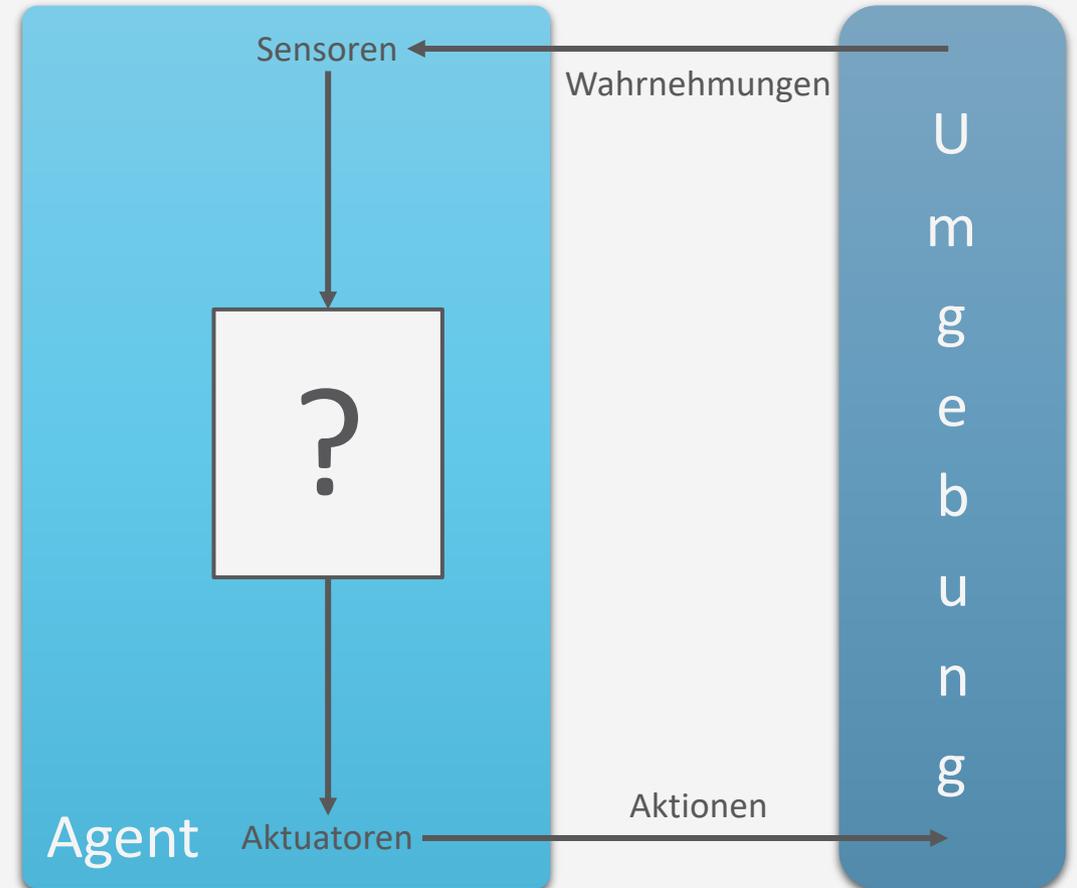
- PEAS
- Eigenschaften

## D. *Agentenstruktur*

- Reflexiv, modellbasiert, zielbasiert, nutzenbasiert, lernend

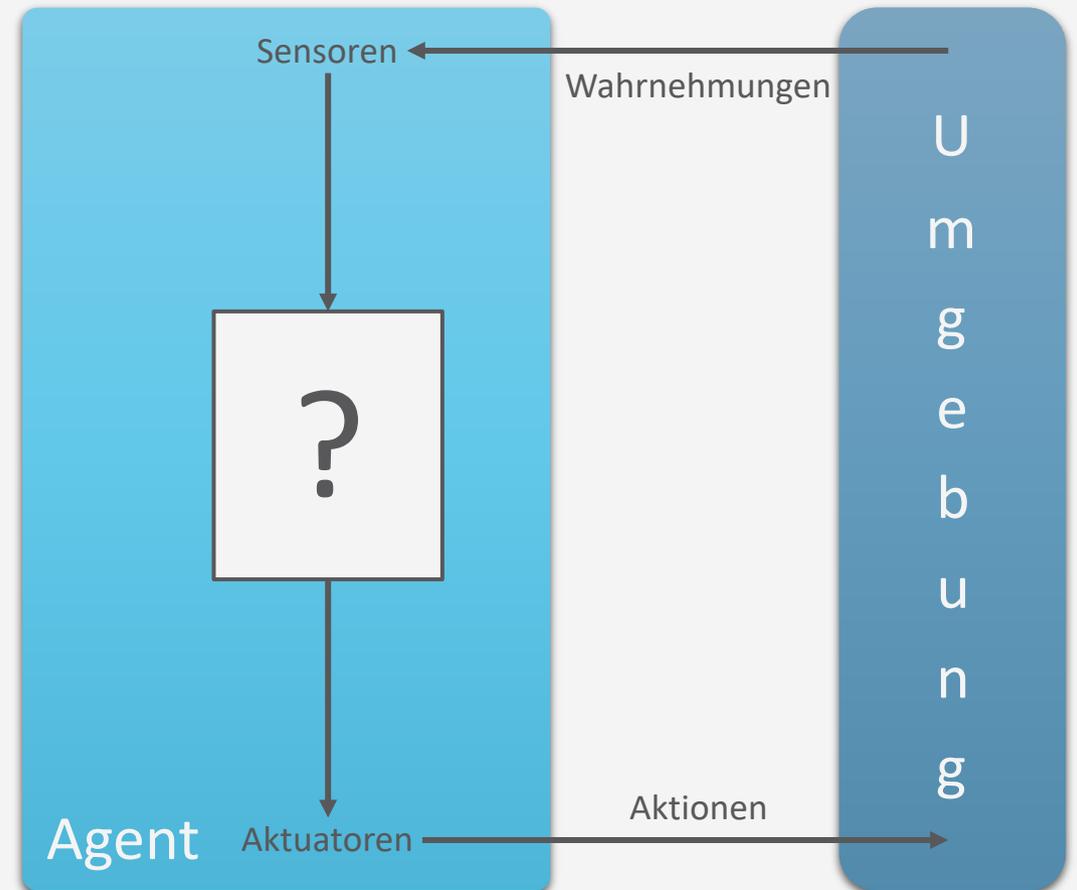
# Agent

- Etwas, was seine **Umgebung** durch **Sensoren** **wahrnimmt** und darin durch **Aktuatoren** handelt
  - Menschlicher Agent
    - Sensoren: Augen, Ohren, weitere Organe
    - Aktuatoren: Hände, Beine, Mund, weitere Körperteile
  - Roboter Agent
    - Sensoren: Kameras, Infrarot-Sensoren, etc.
    - Aktuatoren: Motoren
  - Software Agent
    - Ziel: Dokumentenrückgabe (*document retrieval, DR*)
    - Sensoren: Eingabeschnittstelle für textuelle Anfragen
    - Aktuatoren: Ausgabeschnittstelle für Dokumente



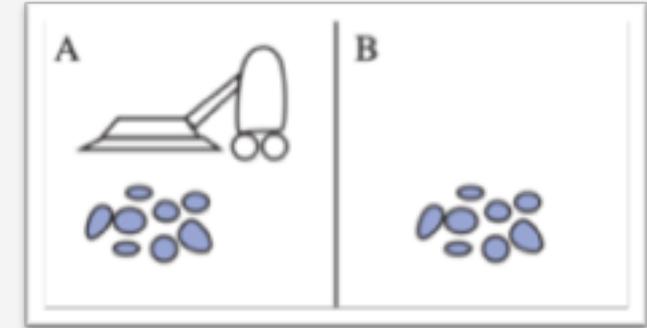
# Verhalten des Agenten

- **Agentenfunktion**
  - Abbildung von Wahrnehmungsfolgen auf Aktionen  
 $f : P^* \rightarrow A$ 
    - $P^*$  Menge der möglichen Wahrnehmungsfolgen
    - $A$  Menge der möglichen Aktionen
- **Agentenprogramm**
  - Implementierung der Agentenfunktion  $f$
  - Läuft auf einem physischem System (**Architektur**)
- **Agent = Architektur + Agentenprogramm**



## Einfaches Beispiel

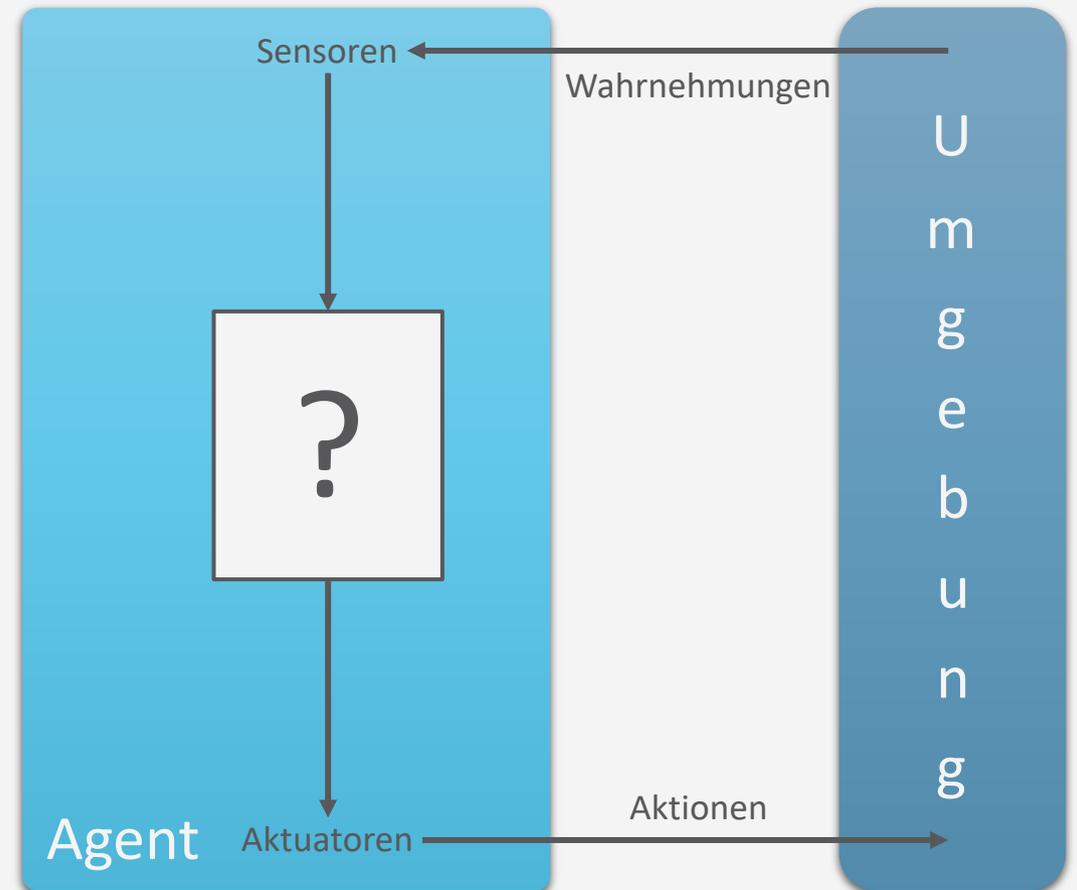
- Staubsaugerroboter
  - Zwei Positionen: *A*, *B*
  - Mögliche Wahrnehmungen: *Sauber*, *Schmutzig*
  - Mögliche Aktionen: *Rechts*, *Links*, *Saugen*
- Agentenfunktion in tabellarischer Darstellung
  - Abbildung von länger werdenden Wahrnehmungsfolgen auf Aktionen
    - Optimierungsfähig, da Aktion nur von der letzten Beobachtung und nicht der ganzen Folge abhängt
  - Wie die Tabelle rechts gefüllt wird, definiert den Agenten
    - Unterschiedliche Agenten möglich
    - Frage: **Was ist richtig? Was ist dumm bzw. intelligent?**



Wahrnehmungsfolge	Aktion
[ <i>A</i> , <i>Sauber</i> ]	<i>Rechts</i>
[ <i>A</i> , <i>Schmutzig</i> ]	<i>Saugen</i>
[ <i>B</i> , <i>Sauber</i> ]	<i>Links</i>
[ <i>B</i> , <i>Schmutzig</i> ]	<i>Saugen</i>
[ <i>A</i> , <i>Sauber</i> ], [ <i>A</i> , <i>Sauber</i> ]	<i>Rechts</i>
[ <i>A</i> , <i>Sauber</i> ], [ <i>A</i> , <i>Schmutzig</i> ]	<i>Saugen</i>
...	...
[ <i>A</i> , <i>Sauber</i> ], [ <i>A</i> , <i>Sauber</i> ], [ <i>A</i> , <i>Sauber</i> ]	<i>Rechts</i>
[ <i>A</i> , <i>Sauber</i> ], [ <i>A</i> , <i>Sauber</i> ], [ <i>A</i> , <i>Schmutzig</i> ]	<i>Saugen</i>
...	...

## Gutes Verhalten

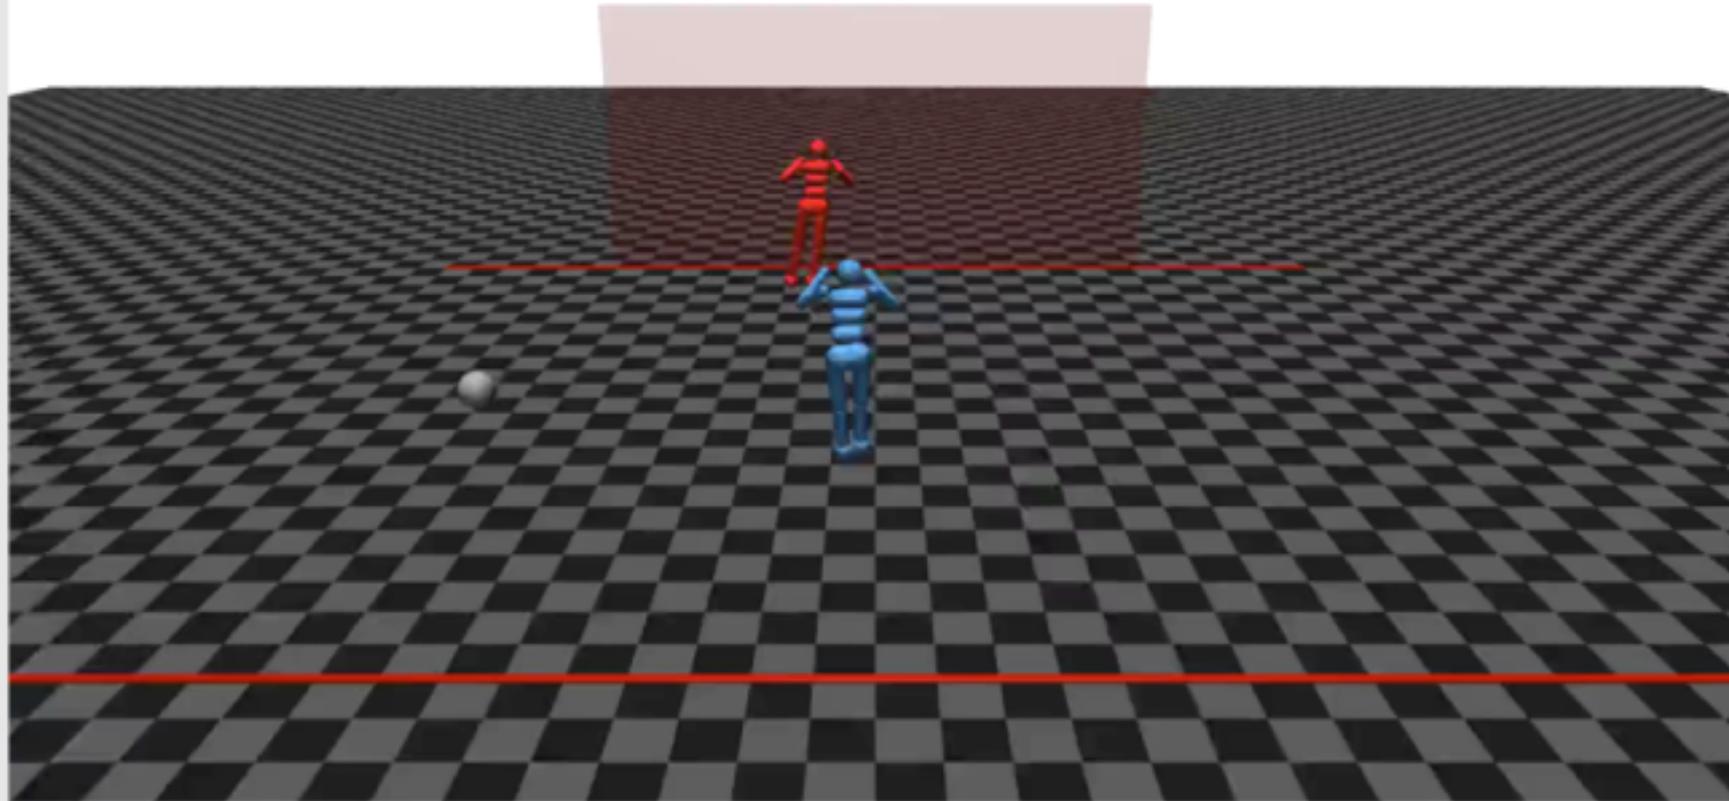
- Was ist das Richtige?
  - Agent generiert Sequenz von Aktionen entsprechend den Wahrnehmungen
  - Das veranlasst die Umgebung eine Folge von Zuständen zu durchlaufen
  - Entspricht diese Folge unseren Vorstellungen, hat sich der Agent gut verhalten
- **Leistungsmaß**, das jede gegebene Sequenz von **Umgebungszuständen** auswertet



Opponent = 0  
Normal (ZooO1)

Ties = 0

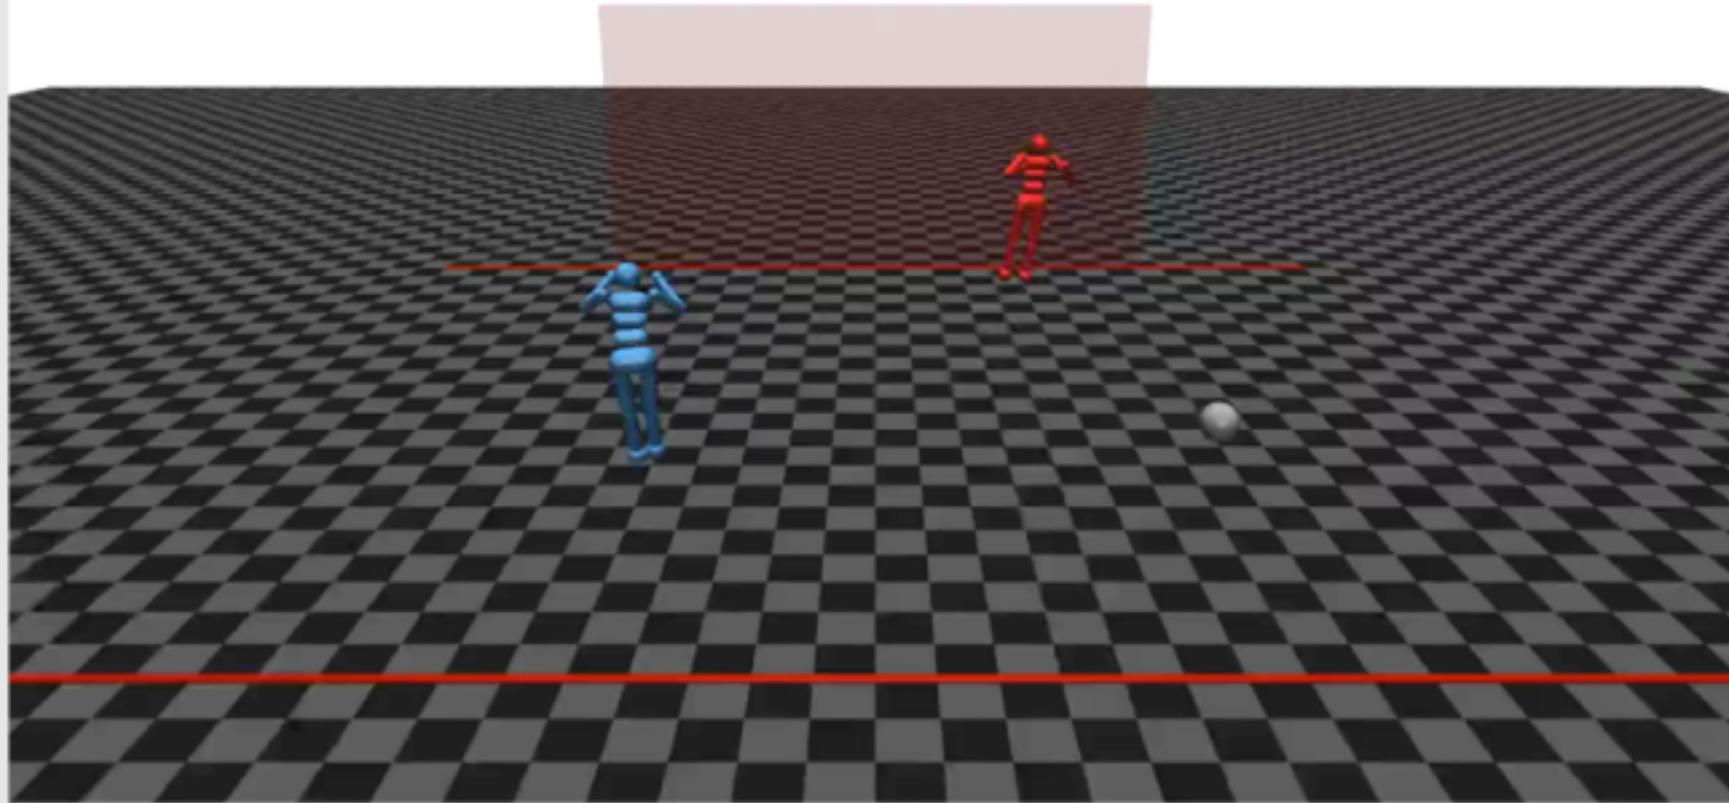
Victim = 0  
Normal (ZooV1)



Opponent = 0  
Adversary (Adv1)

Ties = 0

Victim = 0  
Normal (ZooV1)



# Leistungsmaße

- Schwer festzusetzen
  - Kein allgemein gültiges Maß vorhanden

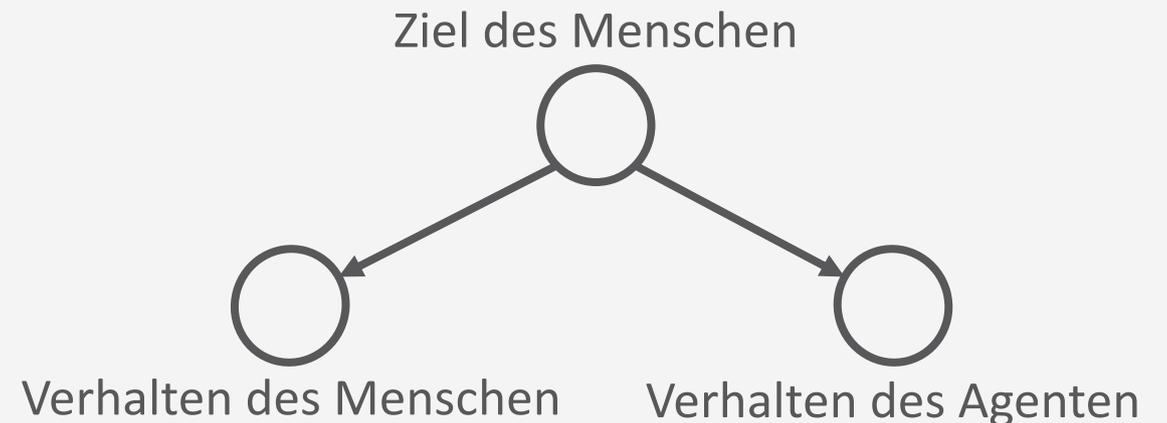
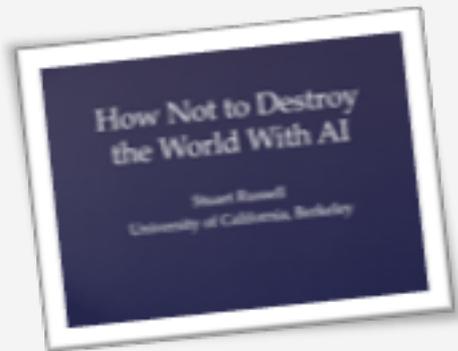
Es ist besser, Leistungsbewertungen nicht danach zu entwickeln, was man tatsächlich in der Umgebung haben will, sondern danach, wie man glaubt, dass sich der Agent verhalten soll.



Wahrnehmungsfolge	Aktion
[A, Sauber]	Rechts
[A, Schmutzig]	Saugen
[B, Sauber]	Links
[B, Schmutzig]	Saugen
[A, Sauber], [A, Sauber]	Rechts
[A, Sauber], [A, Schmutzig]	Saugen
...	...
[A, Sauber], [A, Sauber], [A, Sauber]	Rechts
[A, Sauber], [A, Sauber], [A, Schmutzig]	Saugen
...	...

## Hinweis: Aktuelle Forschung

- Idee:
  - **Menschen**: intelligent in dem Maße, dass zu erwarten ist, dass **unsere** Aktionen **unsere** Ziele erreichen
  - ~~Maschinen~~: intelligent in dem Maße, dass zu erwarten ist, dass **deren** Aktionen **deren** Ziele erreichen
  - **Maschinen** sind *nützlich* in dem Maße, dass zu erwarten ist, dass **deren** Aktionen **unsere** Ziele erreichen
- Umsetzung: Bewertungs-/Zielfunktion unbekannt lassen, Mensch als Assistent
- Ziel: *Provably beneficial AI*
- Siehe zum Beispiel Stuart Russell



## Eigenschaften von Agenten

- Eigenschaften, die Agenten in ihrem Verhalten erfüllen können:

- Rational

- Flexibel

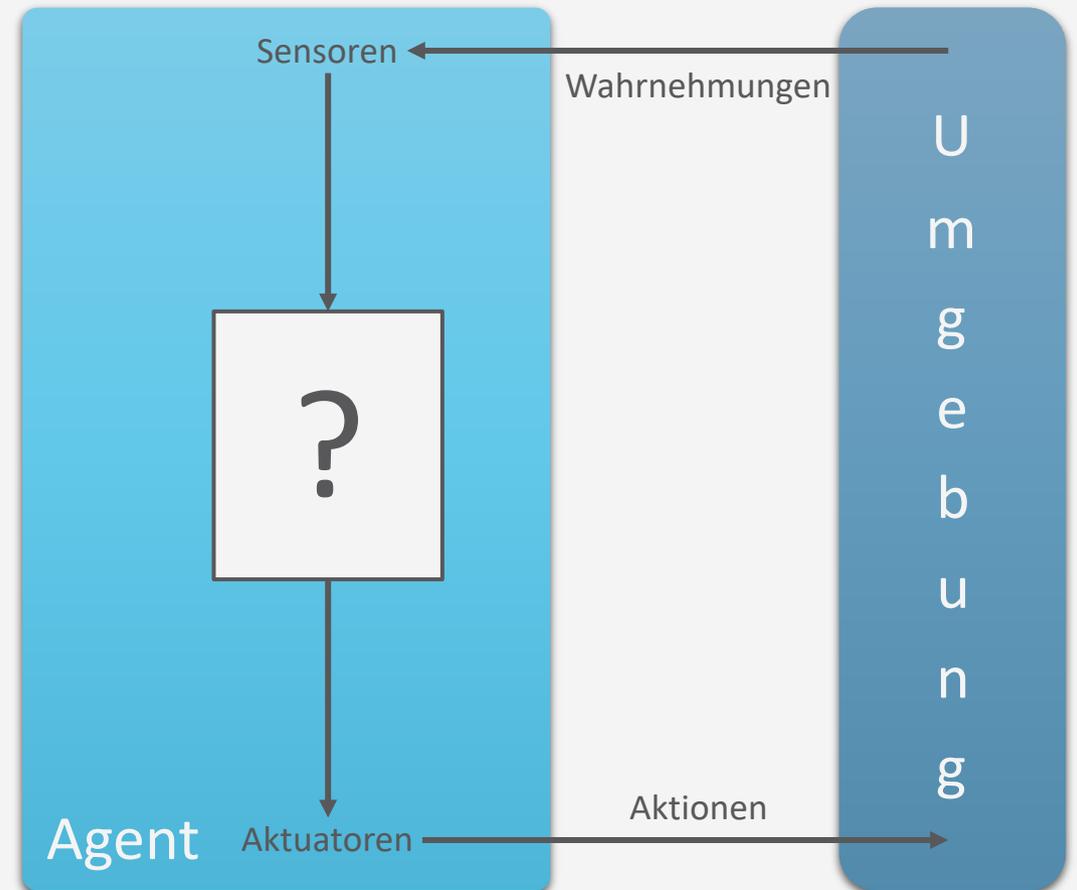
- Reagierend

- Proaktiv

- Sozial

- Autonom

- ...

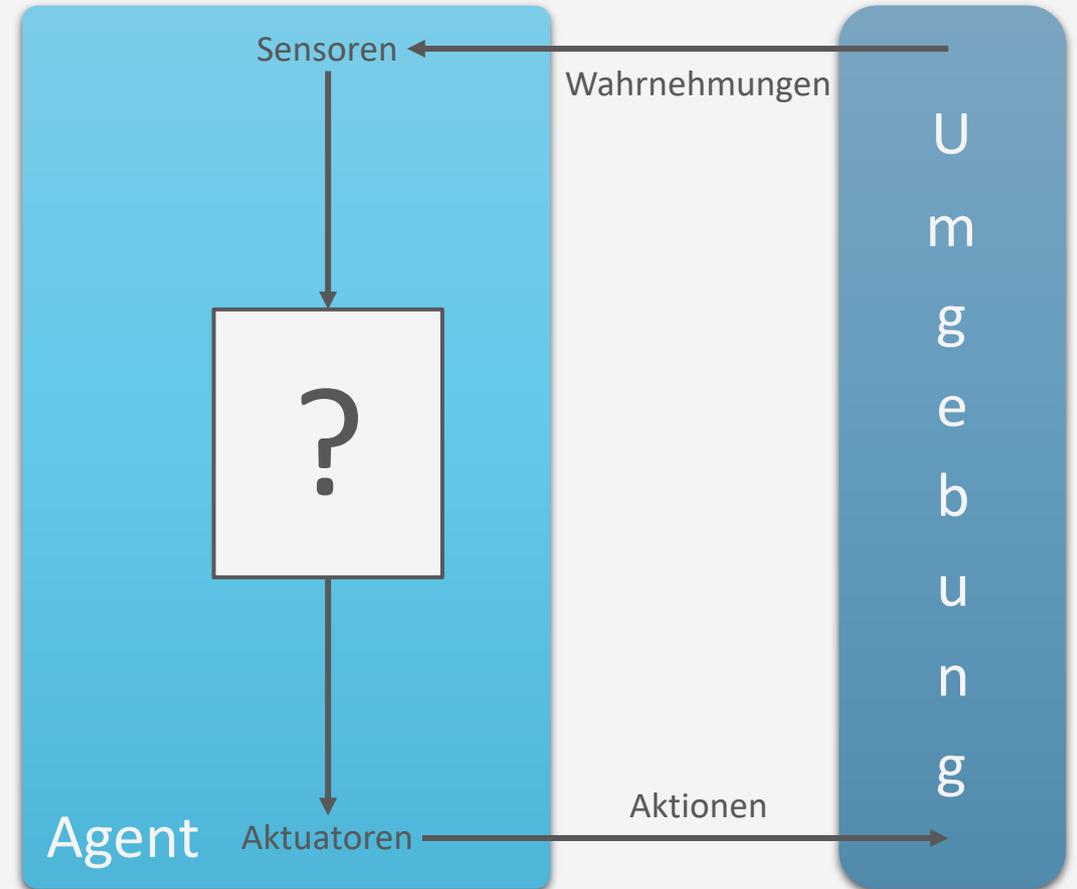


# Rationalität

- **Rationaler Agent:**
  - Für jede mögliche Wahrnehmungsfolge eine *Aktion* auswählen
  - von der erwartet werden kann, dass es die *Leistungsbewertung* maximiert,
  - wenn man die *Wahrnehmungsfolge* sowie
  - verfügbares *Wissen* in Betracht zieht

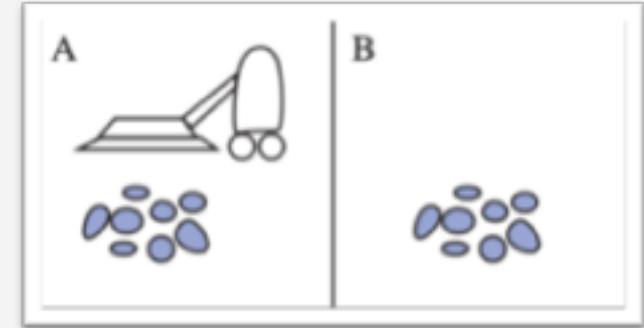
→ Rational = Intelligent

- **Rationalität ist nicht gleich Allwissenheit!**



# Zurück zum Staubsaugerroboter

Unter diesen Umständen rational?

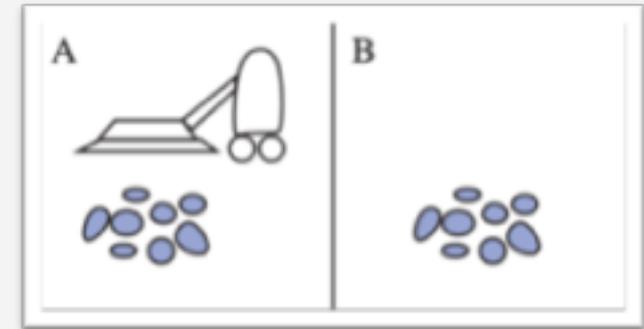


- Leistungsbewertung
  - 1 Punkt für jedes saubere Quadrat in jedem Zeitschritt über eine „Lebensdauer“ von 1000 Zeitschritten
- Umgebung
  - Geographie (A, B) a priori bekannt
  - Nicht bekannt: Ausgangsposition, Schmutzverteilung
  - Aktion *Saugen* reinigt das aktuelle Quadrat; saubere Quadrate bleiben sauber
  - Aktionen *Links* und *Rechts* bewegen den Agenten entsprechend, außer er würde die Umgebung verlassen; dann bleibt er, wo er ist
  - Position und Verschmutzung werden korrekt erkannt

Wahrnehmungsfolge	Aktion
[A, Sauber]	<i>Rechts</i>
[A, Schmutzig]	<i>Saugen</i>
[B, Sauber]	<i>Links</i>
[B, Schmutzig]	<i>Saugen</i>
[A, Sauber], [A, Sauber]	<i>Rechts</i>
[A, Sauber], [A, Schmutzig]	<i>Saugen</i>
...	...
[A, Sauber], [A, Sauber], [A, Sauber]	<i>Rechts</i>
[A, Sauber], [A, Sauber], [A, Schmutzig]	<i>Saugen</i>
...	...

## Zurück zum Staubsaugerroboter

Unter diesen Umständen rational?



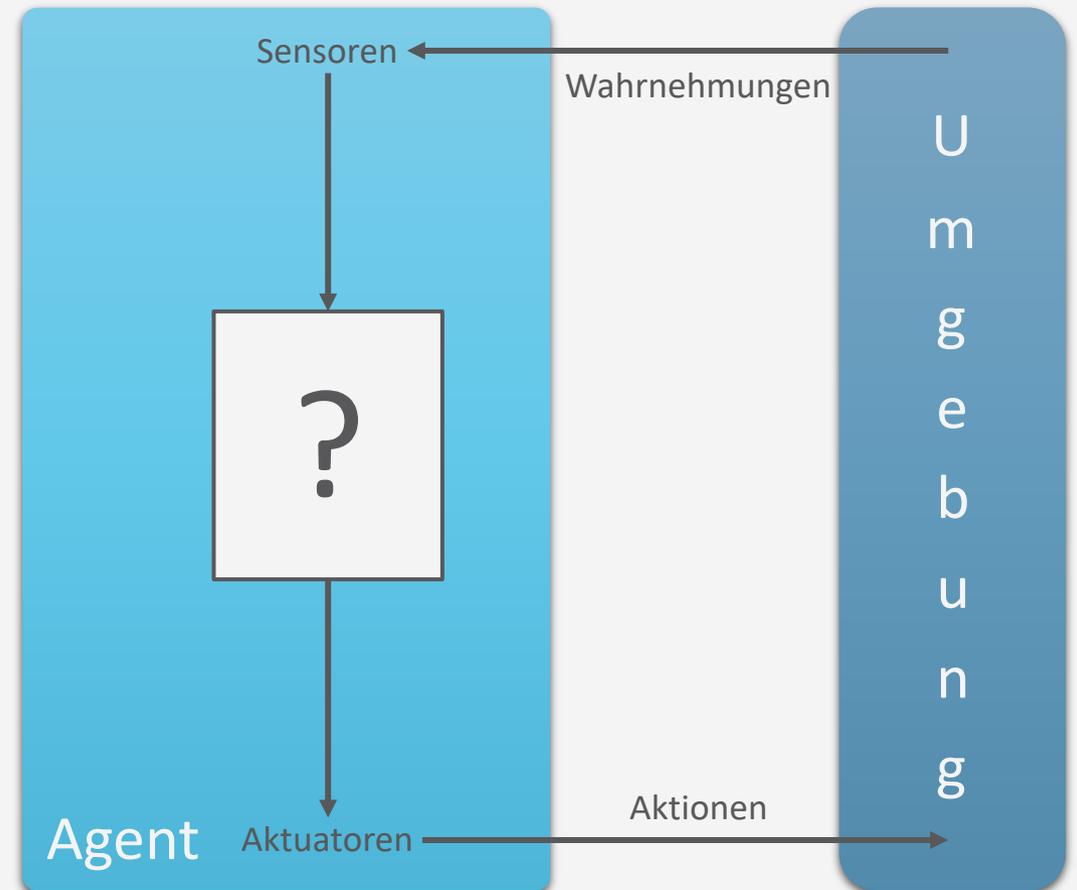
- Leistungsbewertung
  - 1 Punkt für jedes saubere Quadrat in jedem Zeitschritt über eine „Lebensdauer“ von 1000 Zeitschritten
  - 1 Punkt Abzug für jede *Links* bzw. *Rechts* Aktion
- Umgebung
  - Wie zuvor
- Weitere Aktion: *No-Op*
  - Agentenfunktion anpassen, so dass im schmutzigsten Fall beide Quadrate einmal geputzt werden, danach *No-Op*
  - Wenn die Quadrate wieder schmutzig werden können, in bestimmten Zeitabständen Putzrunde wiederholen

Wie erhalten wir einen besseren Agenten?

Wahrnehmungsfolge	Aktion
[A, Sauber]	<i>Rechts</i>
[A, Schmutzig]	<i>Saugen</i>
[B, Sauber]	<i>Links</i>
[B, Schmutzig]	<i>Saugen</i>
[A, Sauber], [A, Sauber]	<i>Rechts</i>
[A, Sauber], [A, Schmutzig]	<i>Saugen</i>
...	...
[A, Sauber], [A, Sauber], [A, Sauber]	<i>Rechts</i>
[A, Sauber], [A, Sauber], [A, Schmutzig]	<i>Saugen</i>
...	...

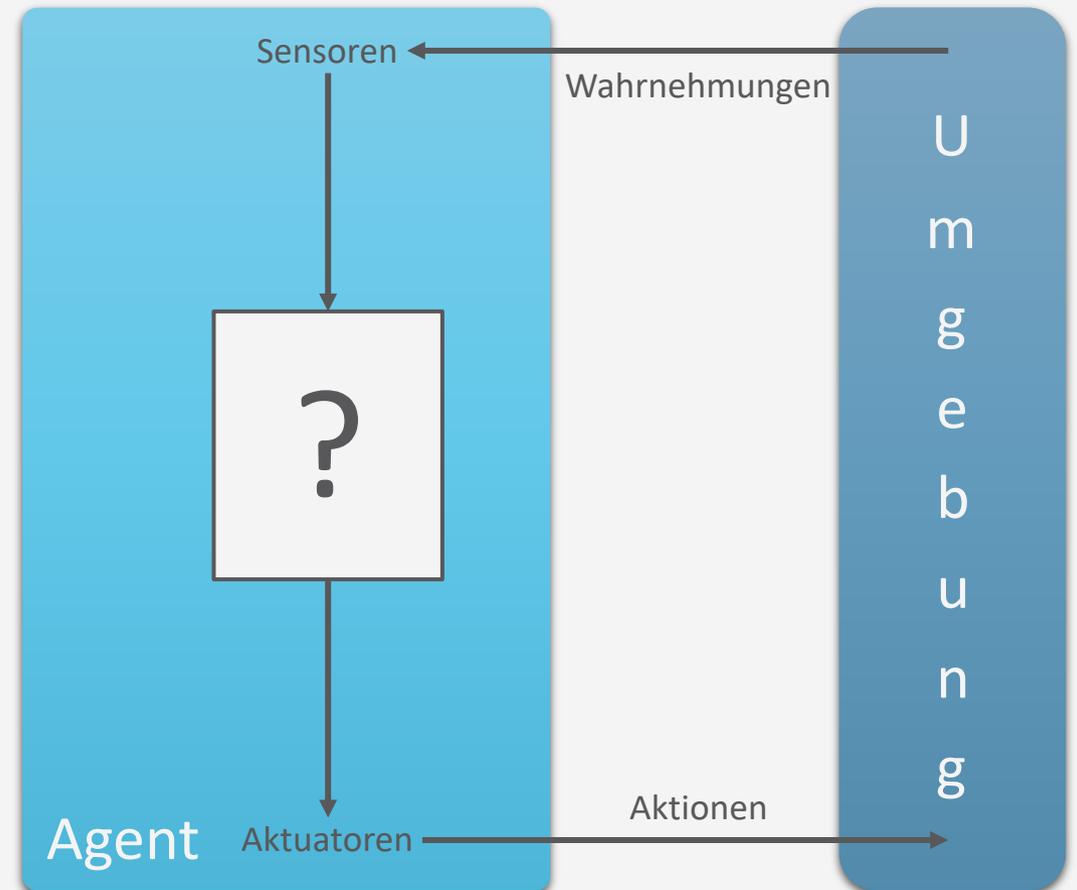
## Eigenschaften von Agenten

- Eigenschaften, die Agenten in ihrem Verhalten erfüllen können:
  - Rational
  - Flexibel
    - Reagierend
    - Proaktiv
    - Sozial
  - Autonom
  - ...



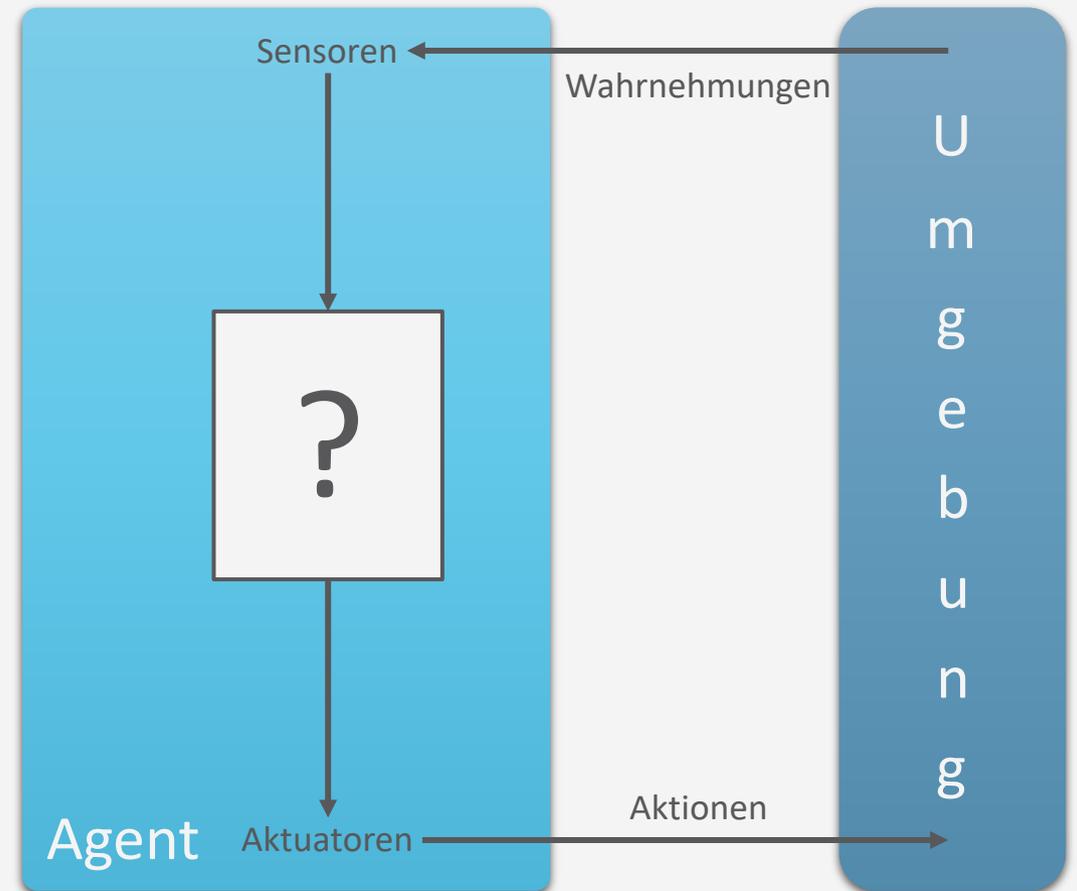
## Flexibilität im Agentenverhalten

- Agent verhält sich **flexibel** in einer Umgebung
  - Passt sein Verhalten den Gegebenheiten der Umgebung an bzw.
- Arten von Flexibilität im Verhalten
  - **Reagierend**
  - **Proaktiv**
  - **Sozial**



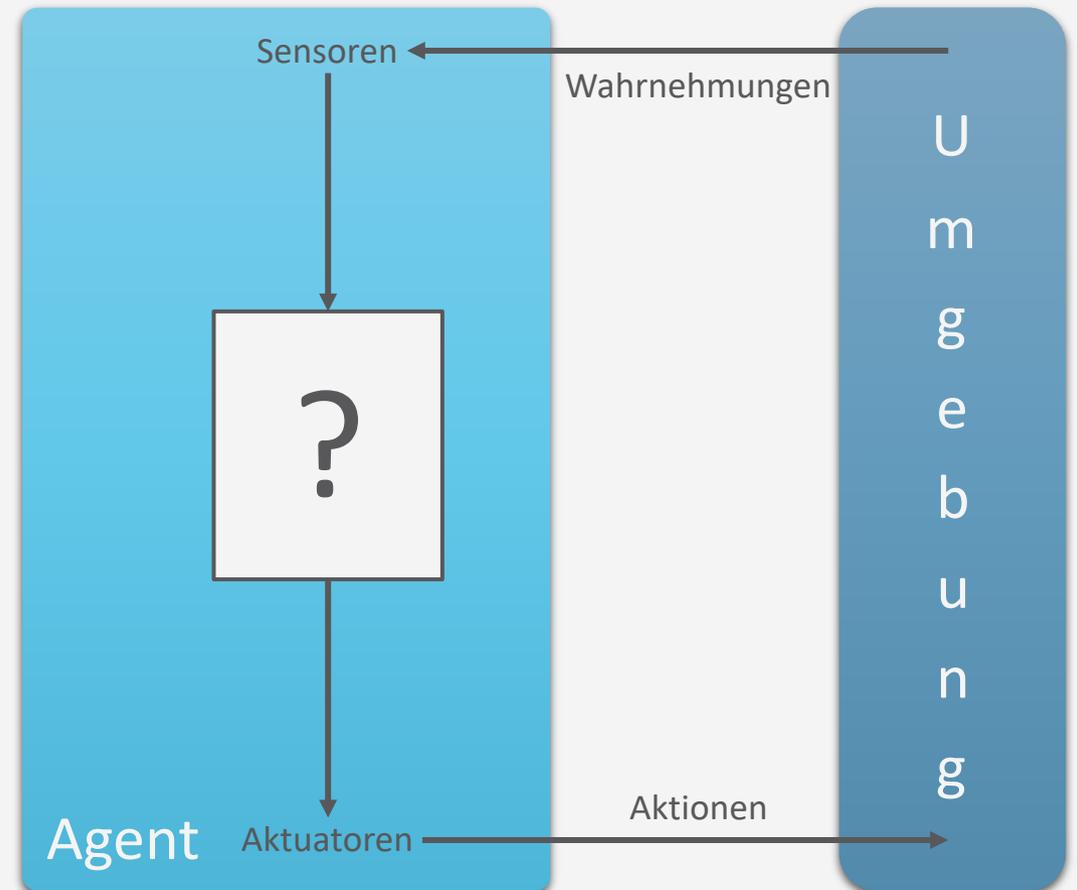
## Flexibilität: *Reagierendes Verhalten*

- **Reagierendes System**
  - Laufende Interaktion mit der Umgebung
  - Reagiert auf Änderungen, die in der Umgebung passieren
    - *Rechtzeitig*, so dass die Reaktion nützlich ist



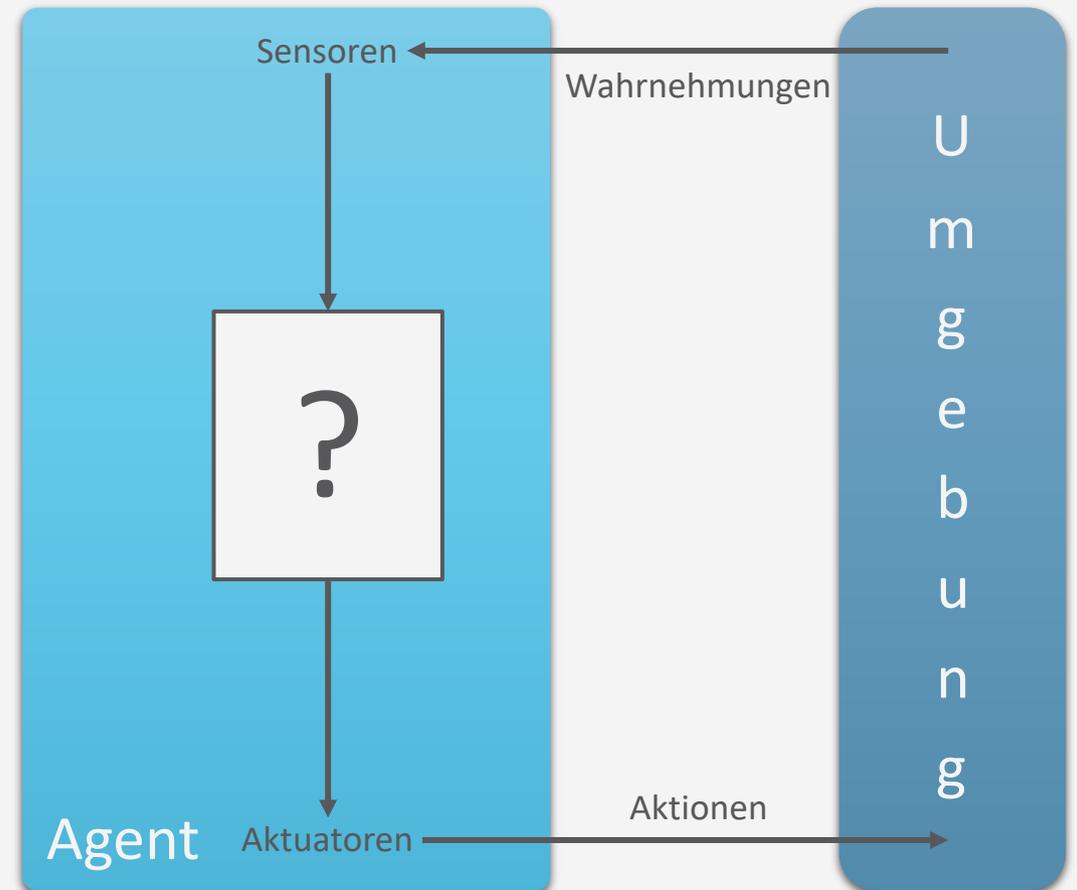
## Flexibilität: *Proaktives Verhalten*

- Auf eine Umgebung zu reagieren ist einfach
  - Regeln: Wahrnehmung → Aktion
- Zweck des Systems: Ziel erreichen
  - Zielbasiertes Verhalten
- **Proaktives** System
  - Nicht nur Ereignis getrieben (reagierend)
  - Erschließen und Verfolgen von Zielen
  - Initiative ergreifen
  - Gelegenheiten ergreifen



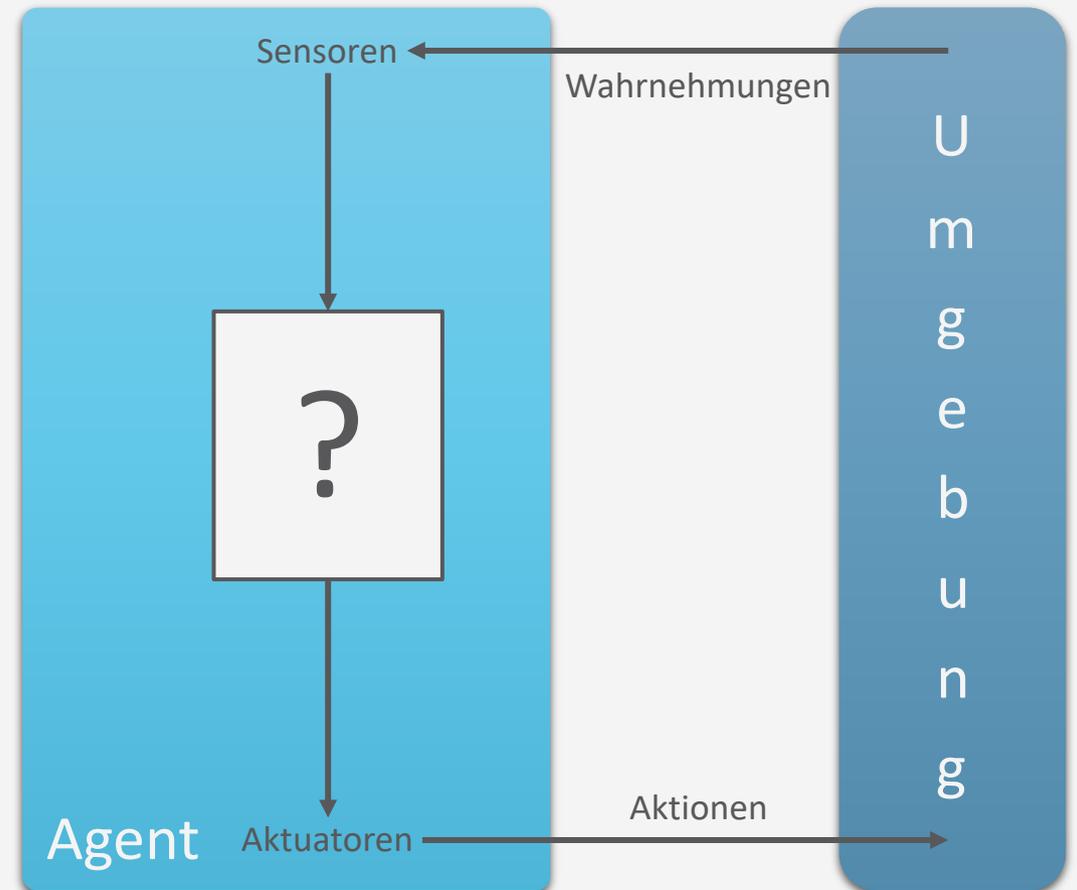
## Das Abwägen zwischen reagierendem und proaktivem Verhalten

- Einerseits reagierendes Verhalten gewünscht
  - Auf sich ändernde Bedingungen auf annehmbare Weise und in annehmbarer Zeit reagieren
- Andererseits proaktives Verhalten gewünscht
  - Auf langfristige Ziele hinarbeiten
- Beide Verhaltensweisen können sich gegenseitig behindern
  
- Offene Forschungsfrage
  - Design eines Agenten, der beide Verhaltensweisen im Gleichgewicht hält



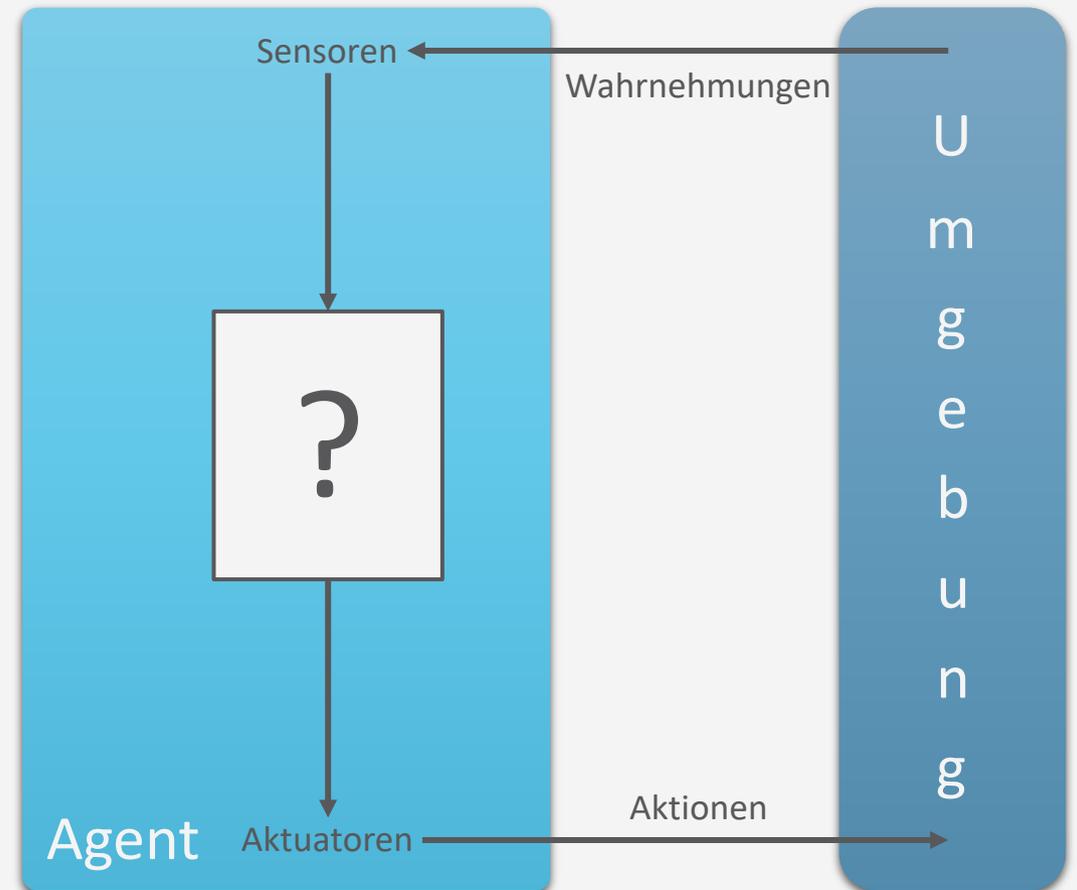
## Flexibilität: *Soziales Verhalten*

- Reale Welt ist eine **Multi-Agenten-Umgebung**
  - Inklusive Menschen
- Effekte
  - Berücksichtigung anderer Agenten erforderlich
  - Manche Ziele können nur durch Kooperation erreicht werden
- **Soziales Verhalten** in Agenten
  - Fähigkeit mit anderen Agenten mittels einer Agentensprache zur Kommunikation zu interagieren
  - Mit dem Ziel mit anderen Agenten verbindliche Absprachen einzugehen



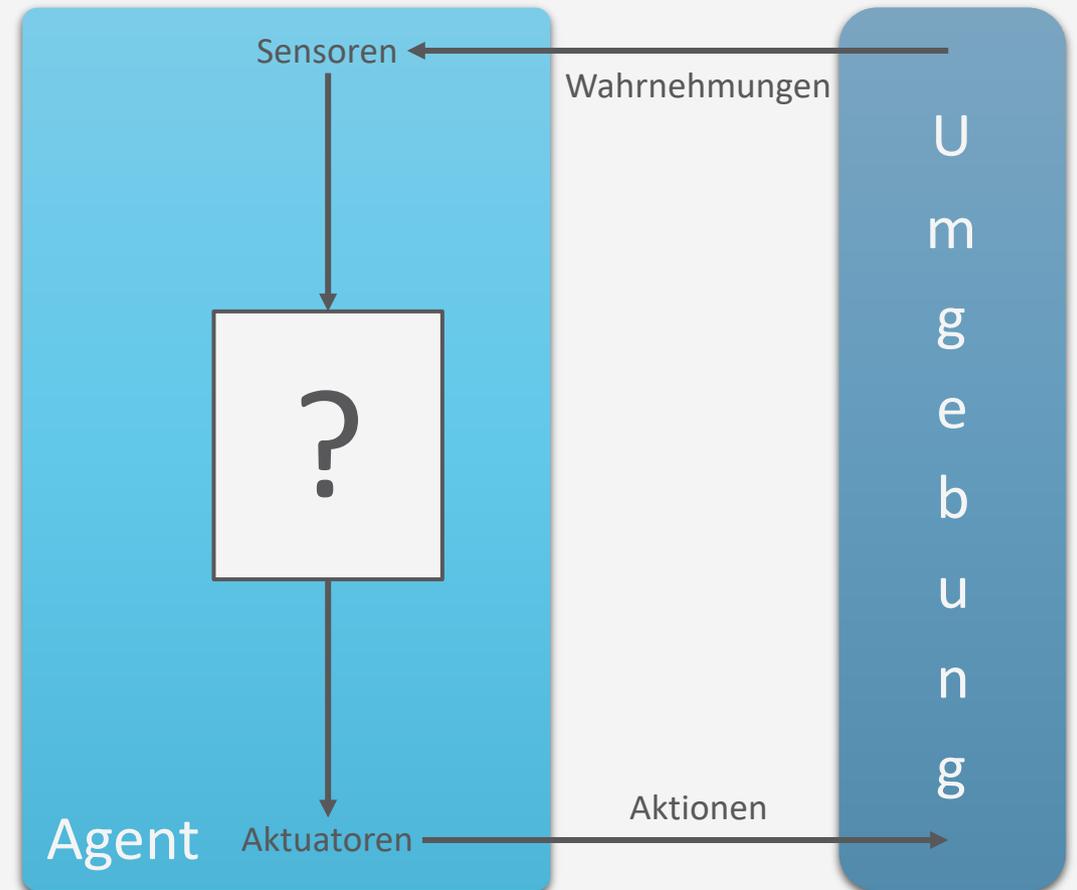
## Eigenschaften von Agenten

- Eigenschaften, die Agenten in ihrem Verhalten erfüllen können:
  - Rational
  - Flexibel
    - Reagierend
    - Proaktiv
    - Sozial
  - **Autonom**
  - ...



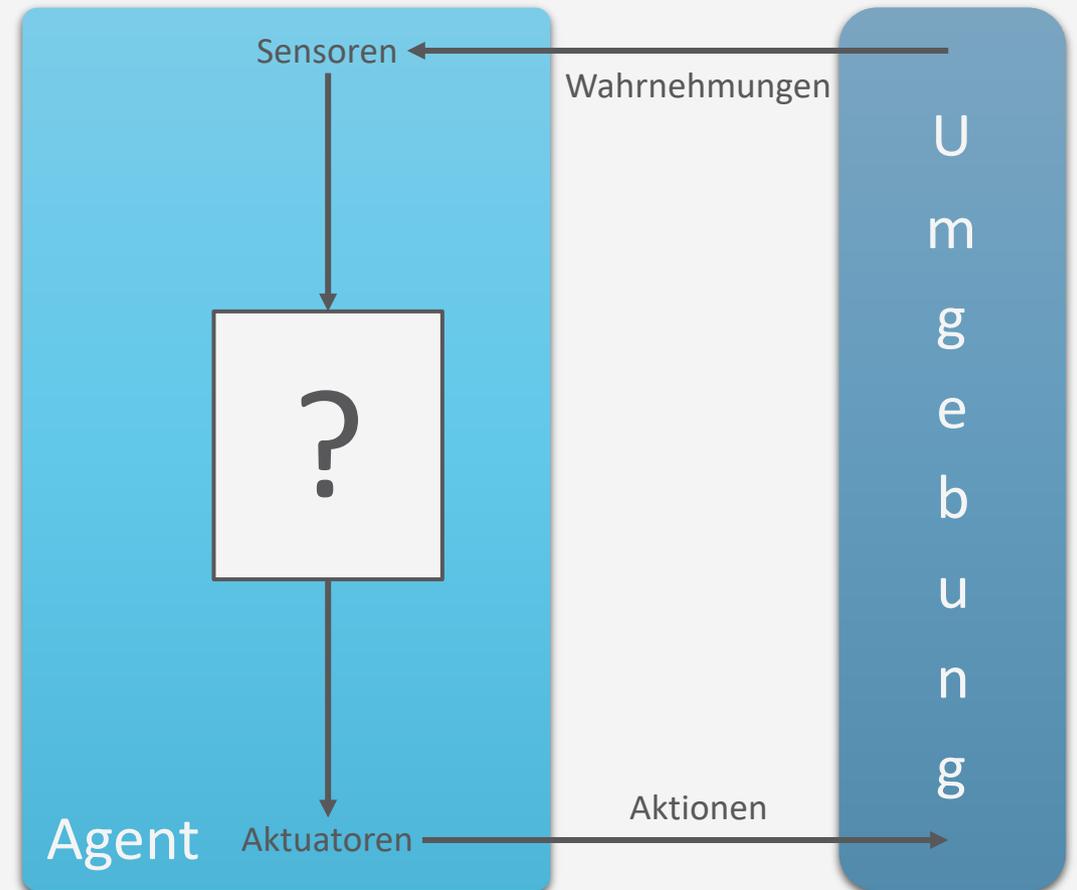
## Autonomie im Agentenverhalten

- Agenten können Aktionen ausführen um zukünftige Wahrnehmungen zu verändern
  - Auch Informationen sammeln genannt
    - **Exploration**: Erkunden / (Kennen-) Lernen einer Umgebung
    - Beispiel Saugroboter bei unbekannter Umgebung: Geographie (Anzahl & Anordnung Quadrate) lernen
- Agent ist **autonom**, falls sein Verhalten durch die eigene Erfahrung bestimmt ist
  - Initiales Wissen über die Umgebung vorgegeben
  - Wissen anpassen und erweitern durch Sammeln von Informationen
    - Lernen aus Wahrnehmungsfolgen



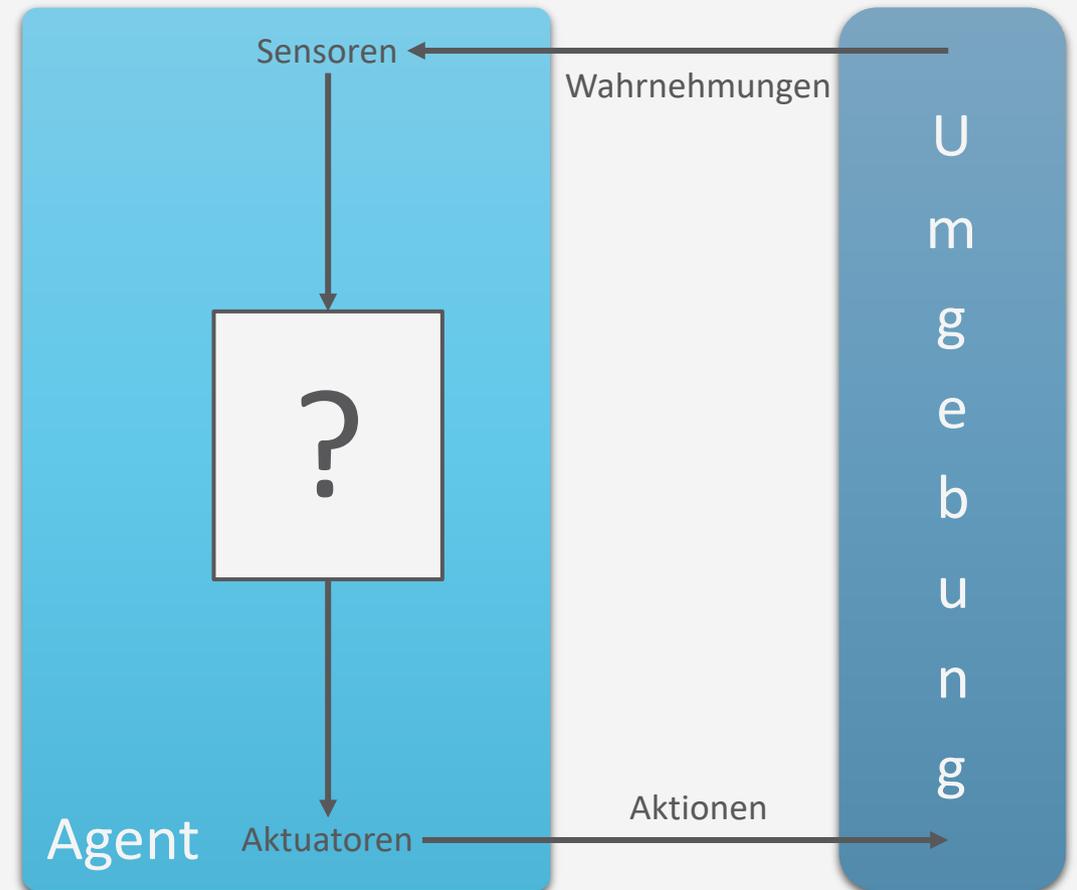
## Eigenschaften von Agenten

- Eigenschaften, die Agenten in ihrem Verhalten erfüllen können:
  - Rational
  - Flexibel
    - Reagierend
    - Proaktiv
    - Sozial
  - Autonom
  - ...



## Weitere mögliche Eigenschaften von Agenten

- **Mobilität** (*mobility*)
  - Fähigkeit eines Agenten sich in einer Umgebung zu bewegen
- **Aufrichtigkeit** (*veracity*)
  - Ein Agent gibt nicht wissentlich falsche Information weiter
- **Gutmütigkeit** (*benevolence*)
  - Agenten haben keine sich widersprechenden Ziele
  - Jeder Agent wird deshalb immer versuchen das zu tun, was von ihm erwartet wird
- **Lernen / Anpassung** (*learning / adaptation*)
  - Agenten verbessern ihre Leistung über die Zeit



## Zwischenzusammenfassung

- Agent
  - Etwas, was seine **Umgebung** durch **Sensoren wahrnimmt** und darin durch **Aktuatoren handelt**
  - Agentenprogramm + Architektur
    - Agentenprogramm implementiert Agentenfunktion
- Leistungsmaß
  - Abhängig von konkreter Aufgabe
- Eigenschaften von Agenten
  - **Rational**: *Aktion* auswählen, von der erwartet werden kann, dass es die *Leistungsbewertung* maximiert, wenn man die *Wahrnehmungsfolge* sowie verfügbares *Wissen* in Betracht zieht
  - **Flexibel**: Reagierend / proaktiv / sozial verhaltend
  - **Autonom**: Verhalten durch die eigene Erfahrung bestimmt

# Überblick: 1. Künstliche Intelligenz & Agenten

## A. *Was ist KI?*

- Menschliches und rationales Denken & Handeln

## B. *Agenten*

- Agentenabstraktion
- Eigenschaften

## C. *Aufgabenumgebung*

- PEAS
- Eigenschaften

## D. *Agentenstruktur*

- Reflexiv, modellbasiert, zielbasiert, nutzenbasiert, lernend

# Aufgabenumgebung

- Im Wesentlichen die Problemstellung, deren Lösung ein rationaler Agent ist
  - Spezifizierung der Aufgabenumgebung über PEAS-Beschreibung
    - Performance measure (Leistungskriterium)
    - Environment (Umgebung)
    - Actuators (Aktuatoren)
    - Sensors (Sensoren)
- Eigenschaften von Aufgabenumgebungen
- Darstellung der Umgebung
- Bestimmen Design des Agentenprogramms

Achtung: Namenskollision zwischen Aufgabenumgebung und Umgebung (*environment*).  
Wir werden nach dieser Vorlesung in der Regel nur noch von der Umgebung im Speziellen und nicht mehr von der Aufgabenumgebung als Ganzes reden.

## PEAS – Beispiele

- Automatisiertes Taxi

Agententyp	Leistungsbewertung	Umgebung	Aktuatoren	Sensoren
Taxifahrer	sicher, schnell, der Straßenverkehrsordnung gehorchend, angenehme Fahrweise, maximale Gewinne	Straßen, anderer Verkehr, Fußgänger, Fahrgäste	Steuerrad, Gas, Bremse, Hupe, Blinker, Anzeige	Kameras, Sonar, Tachometer, GPS, Kilometerzähler, Motorsensoren, Tastatur

- Medizinisches Diagnosesystem

Agententyp	Leistungs-bewertung	Umgebung	Aktuatoren	Sensoren
Medizinisches Diagnose-system	Gesunder Patient, verringerte Kosten	Patient, Krankenhaus, Team	Anzeige von Fragen, Untersuchungen, Diagnosen, Behandlungen, Empfehlungen	Tastatureingabe der Symptome, Befunde, Antworten des Patienten

- Website-Operator

- Nachrichtenquellen im Internet durchsuchen
- Benutzer die interessanten Artikel anzeigen
- Werbeflächen verkaufen, um Einnahmen zu erzielen



Wie sieht das bei einem Software-Agenten für DR aus?

# Eigenschaften von Aufgabenumgebungen

- **Vollständig beobachtbar** (vs. **teilweise beobachtbar**)
  - Sensoren bieten zu jedem beliebigen Zeitpunkt Zugriff auf den vollständigen Zustand der Umgebung
- **Einzelagent** (vs. **Multiagenten**)
  - Einzelner Agent handelt in einer Umgebung
  - Teilweise Definitionssache, ob etwas in der Umgebung Objekt oder weiterer Agent ist
- **Deterministisch** (vs. **stochastisch**)
  - Nächste Zustand der Umgebung vollständig durch den aktuellen Zustand und die durch den Agenten ausgeführten Aktionen festgelegt
  - **Strategisch**: Umgebung deterministisch abgesehen von den Aktionen anderer Agenten

## Eigenschaften von Aufgabenumgebungen

- **Episodisch** (vs. **sequentiell**)
  - Erfahrung des Agenten in atomare Episoden unterteilt
    - Episode = Agent empfängt eine Wahrnehmung und führt dann eine einzelne Aktion aus
  - Wahl der Aktion in jeder Episode hängt nur von der Episode selbst ab
- **Statisch** (vs. **dynamisch**)
  - Umgebung ist unverändert während der Agent eine Entscheidung trifft
  - **Semidynamisch**: Umgebung ist statisch, aber die Leistungsbewertung ändert sich
- **Diskret** (vs. **stetig / kontinuierlich**)
  - Bezieht sich auf *Zustand* der Umgebung, *Wahrnehmungen*, *Aktionen*, *Behandlung der Zeit*
  - Endliche Anzahl unterschiedlicher Zustände, Wahrnehmungen, Aktionen, Zeitschritte

Weiteres Kriterium: Bekannt (vs. unbekannt)

- Wissensstand des Agenten bzgl. seiner Umgebung
- *Keine* Eigenschaft der Umgebung

# Eigenschaften von Aufgabenumgebungen – Beispiele

Aufgaben- umgebung	Beob- achtbar	Agenten	Deter- ministisch	Episodisch	Statisch	Diskret
Kreuzwörtertsel	vollständig	Einzel	deterministisch	sequenziell	statisch	diskret
Schach mit Uhr	vollständig	Multi	strategisch	sequenziell	semi- dynamisch	diskret
Taxifahren	teilweise	Multi	stochastisch	sequenziell	dynamisch	stetig
Medizinische Diagnose	teilweise	Einzel	stochastisch	sequenziell	dynamisch	stetig

# Darstellung der Umgebung

- Abhängig von den Eigenschaften der Aufgabenumgebung
    - Diskret/kontinuierlich, statisch/dynamisch, episodisch/sequentiell, ...
  - Dazu Ausdrucksstärke der Kodierung der Umgebung bestimmen
    - Zunehmende Komplexität und Ausdrucksfähigkeit
1. **Atomar**
    - Jeder Zustand unteilbar (keine interne Struktur)
    - „Blackbox“, die zu einer anderen Blackbox identisch sein kann oder nicht
  2. **Faktoriert**
    - Aufteilung des Zustandes in eine feste Menge von Variablen / Attributen, die jeweils einen Wert haben können
    - Durch **PGMs** inklusive Unsicherheit, aber auch durch propositionale Logik darstellbar
  3. **Strukturiert**
    - Objekte und Beziehungen zwischen ihnen
    - In relationalen Datenbanken / PGMs, Logik erster Stufe darstellbar

Werbeblock:  
Vorlesung „*Automated Planning and Acting*“

Diese Vorlesung!

Werbeblock:  
Vorlesung „*Relational Inference and Online Decision Making*“

## Einordnung von PGMs

- PGMs für die faktorisierte Darstellung der Umgebung und Entscheidungsfindung
- PGMs *im Hauptteil dieser Vorlesung* erlauben die Modellierung der Umgebung mit folgenden Eigenschaften
  - Vollständig beobachtbar oder teilweise beobachtbar
  - Einzelagent
  - Stochastisch
  - Episodisch oder sequentiell
  - Statisch
  - Diskret
- Damit nicht berücksichtigt
  - Multiagenten
  - Deterministisch, strategisch
  - Dynamisch
  - Stetig / kontinuierlich
- Ansätze zum Behandeln von Umgebungen mit diesen Eigenschaften teilweise vorhanden

Achtung: In der PGM-Literatur werden die Bezeichnungen *episodisch* und *sequentiell* teilweise durch die Bezeichnungen *statisch* und *dynamisch* ersetzt, während die Bezeichnungen *statisch* und *dynamisch* durch die so genannte *Markov-Annahme* bzw. *(Nicht-)Markov-Abstraktion* abgedeckt werden.

## Zwischenzusammenfassung

- Spezifizierung von Aufgabenumgebungen
  - PEAS
- Eigenschaften von Aufgabenumgebungen
  - **Vollständig beobachtbar (vs. teilweise beobachtbar)**
  - **Einzelagent** (vs. Multiagenten)
  - Deterministisch (vs. **stochastisch**), strategisch
  - **Episodisch (vs. sequentiell)**
  - **Statisch** (vs. dynamisch)
  - **Diskret** (vs. stetig / kontinuierlich)
  - Bekannt (vs. unbekannt)
- Umgebungsdarstellung
  - Atomar, **faktoriert**, strukturiert

Blau markiert:  
Ausdrucksstärke von  
PGMs in dieser Vorlesung

# Überblick: 1. Künstliche Intelligenz & Agenten

## A. *Was ist KI?*

- Menschliches Denken & Handeln
- Rationales Denken & Handeln

## B. *Intelligente Agenten*

- Agentenabstraktion
- Fähigkeiten

## C. *Aufgabenumgebung*

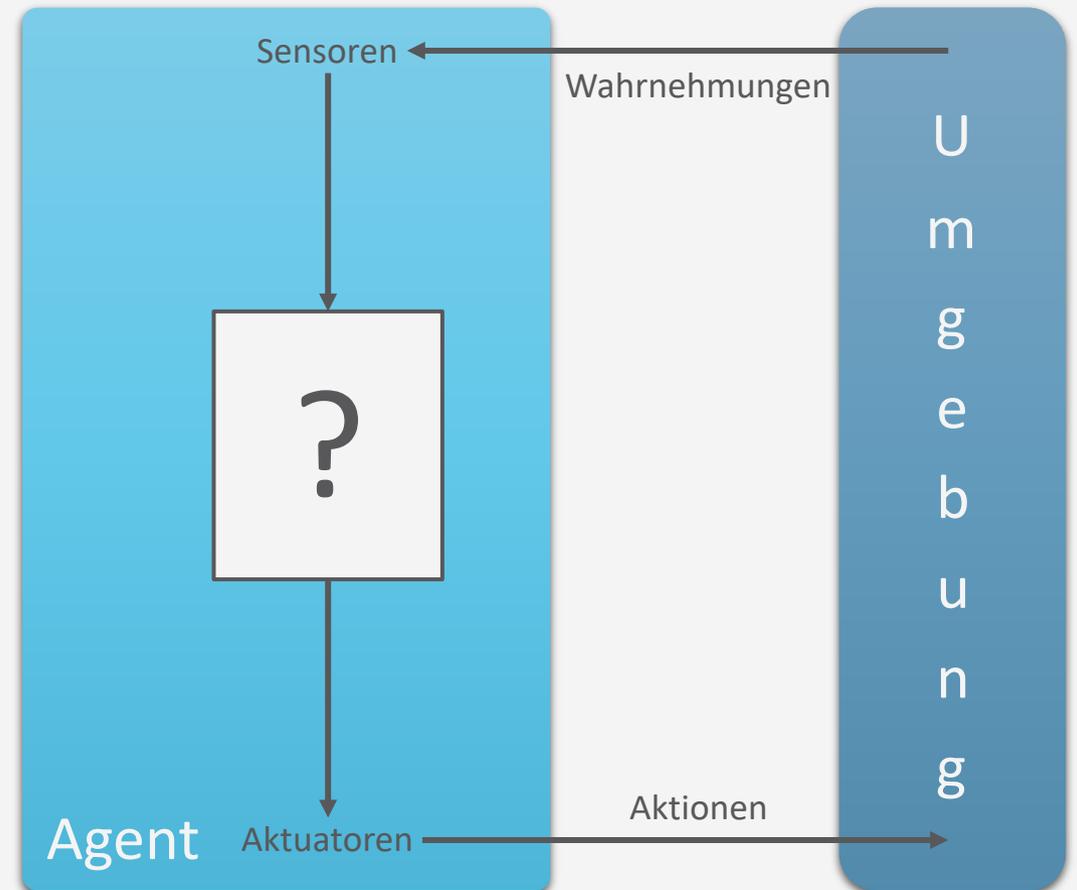
- PEAS
- Eigenschaften

## D. *Agentenstruktur*

- Reflexiv, modellbasiert, zielbasiert, nutzenbasiert, lernend

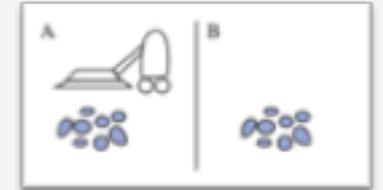
# Implementierung von Agenten

- Agent = Architektur + Programm
  - Architektur
    - Einheit mit entsprechenden physischen Sensoren und Aktuatoren
      - Einheit = Computer, Roboter, Software (Sensoren und Aktuatoren als Schnittstellen)
  - Programm
    - Implementierung einer Agentenfunktion
    - Läuft auf der Architektur
  - Beides durch Aufgabenumgebung vorgegeben
- Implementierung nötig, aber wie?



# Einfacher Tabellensuche-Agent

- Aktion anhand der aktuellen Wahrnehmungsfolge in Tabelle nachschauen



```

function TABLE-DRIVEN-AGENT(percept) returns an action
  persistent: percepts, a sequence, initially empty
               table, a table of actions, indexed by percept sequences

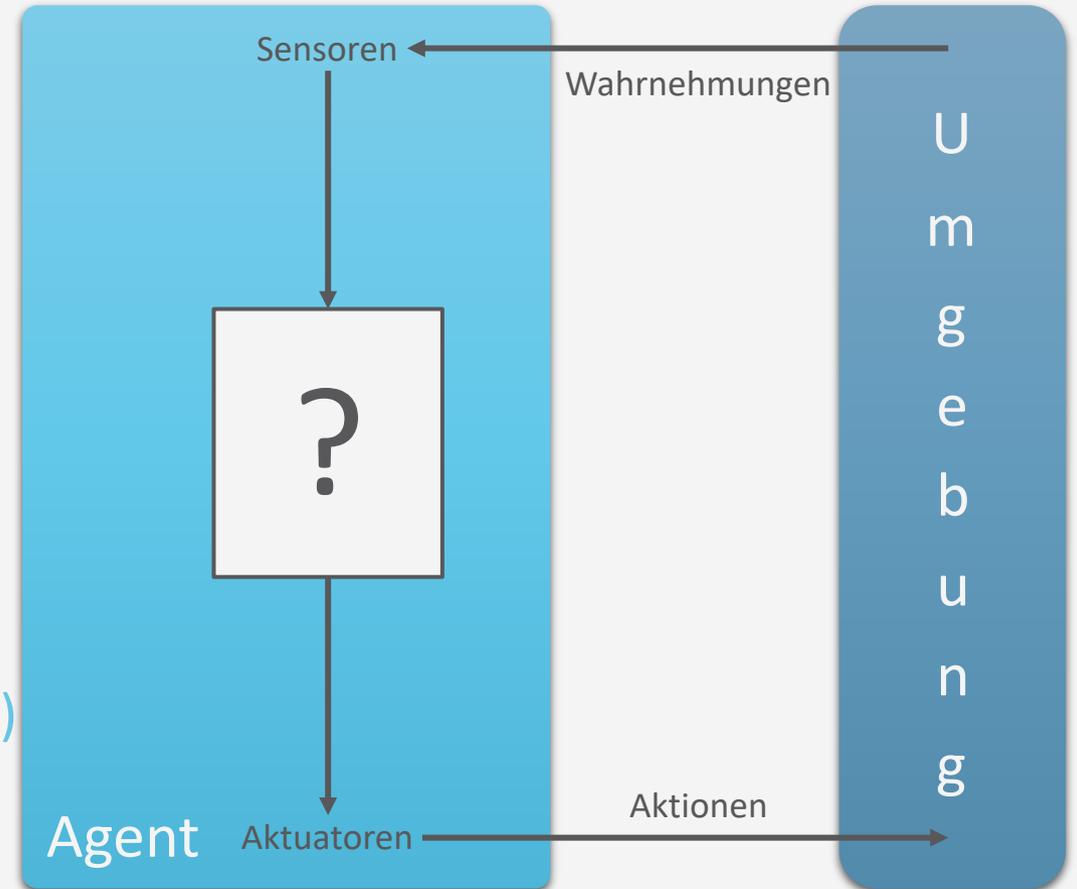
  append percept to the end of percepts
  action ← LOOKUP(percepts, table)
  return action
  
```

- Nachteile
  - Tabelle möglicherweise sehr groß:  $\sum_{t=1}^T |P|^t$ 
    - $P$  Menge der möglichen Wahrnehmungen,  $T$  Lebensdauer
  - Keine Autonomie
  - Dauert lange die Tabelle zu erstellen
    - Automatisiert lernen nicht besser (viele Einträge zu lernen)

Wahrnehmungsfolge	Aktion
[A, Sauber]	Rechts
[A, Schmutzig]	Saugen
[B, Sauber]	Links
[B, Schmutzig]	Saugen
[A, Sauber], [A, Sauber]	Rechts
[A, Sauber], [A, Schmutzig]	Saugen
...	...
[A, Sauber], [A, Sauber], [A, Sauber]	Rechts
[A, Sauber], [A, Sauber], [A, Schmutzig]	Saugen
...	...

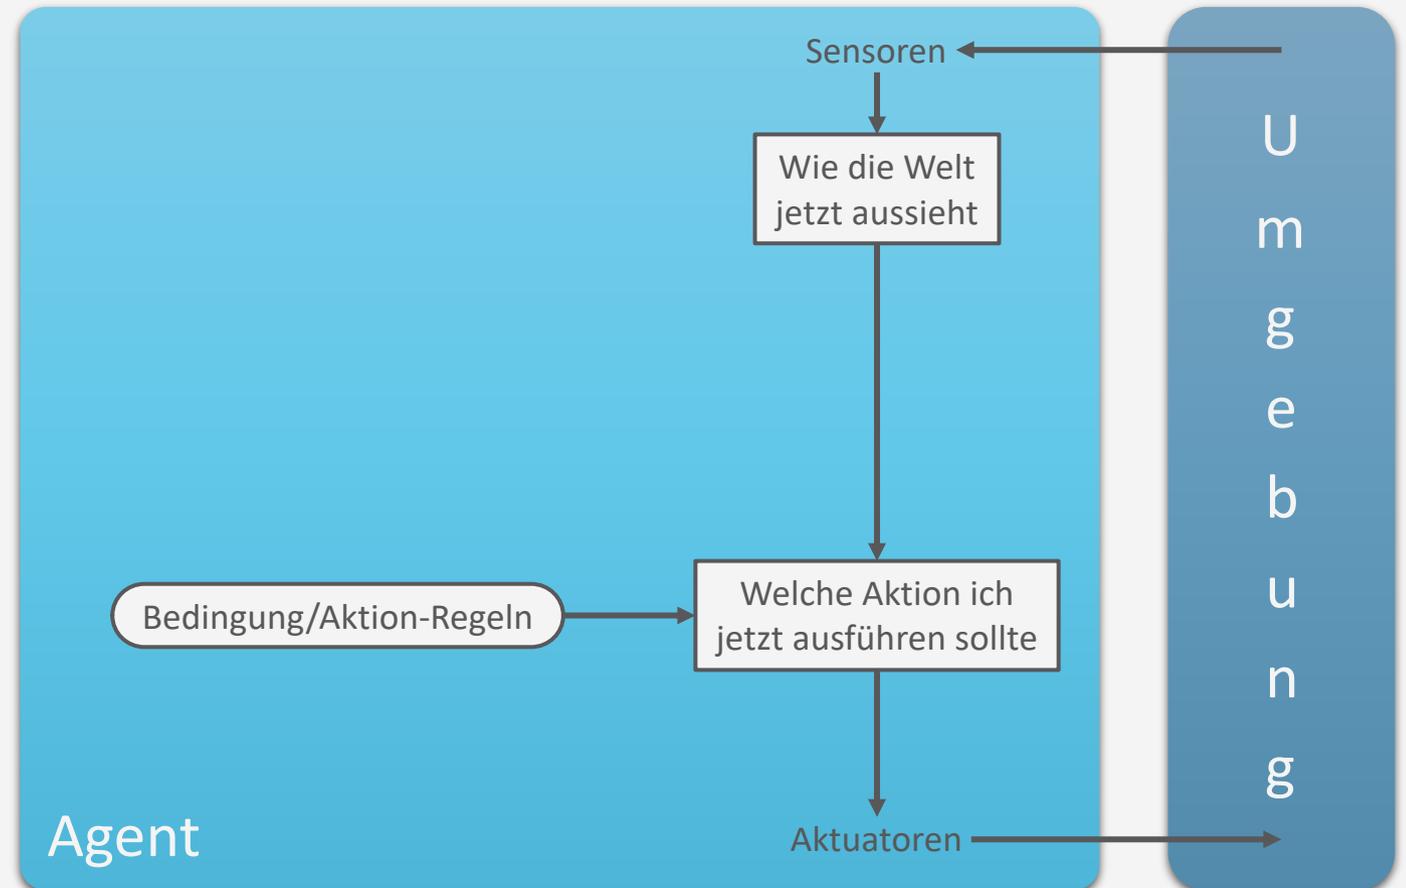
## Struktur von Agenten

- Allgemeine Agentenstrukturen zur Implementierung einer Agentenfunktion:
  - Reihenfolge mit zunehmender Allgemeinheit
    1. Reflexagent
    2. Modellbasierter Reflexagent
    3. Modell- und zielbasierter Agent
    4. Modell- und nutzenbasierter Agent
    5. Lernender Agent
  - ❖ Mensch-bewusster Agent (aus aktueller Forschung)



## Agentenstruktur: Einfacher Reflexagent

- Aktionen auf Grundlage der aktuellen Wahrnehmung wählen
  - Ignoriert den vorhergehenden Wahrnehmungsverlauf
  - Keine Modellierung der Umgebung
- Korrekte Entscheidung nur, wenn die Umgebung vollständig beobachtbar ist
  - Wenn Nicht-Beobachtbarkeit gegeben, Endlosschleifen möglich
    - (Begrenzte) Abhilfe: Aktion zufällig wählen



# Implementierung eines einfachen Reflexagenten

- Allgemeine Darstellung

```
function SIMPLE_REFLEX-AGENT(percept) returns eine Aktion
  persistent: rules, eine Menge von Bedingungs-Aktions-Regeln

  state ← INTERPRET-INPUT(percept)
  rule ← RULE-MATCH(state, rules)
  action ← rule.ACTION
  return action
```

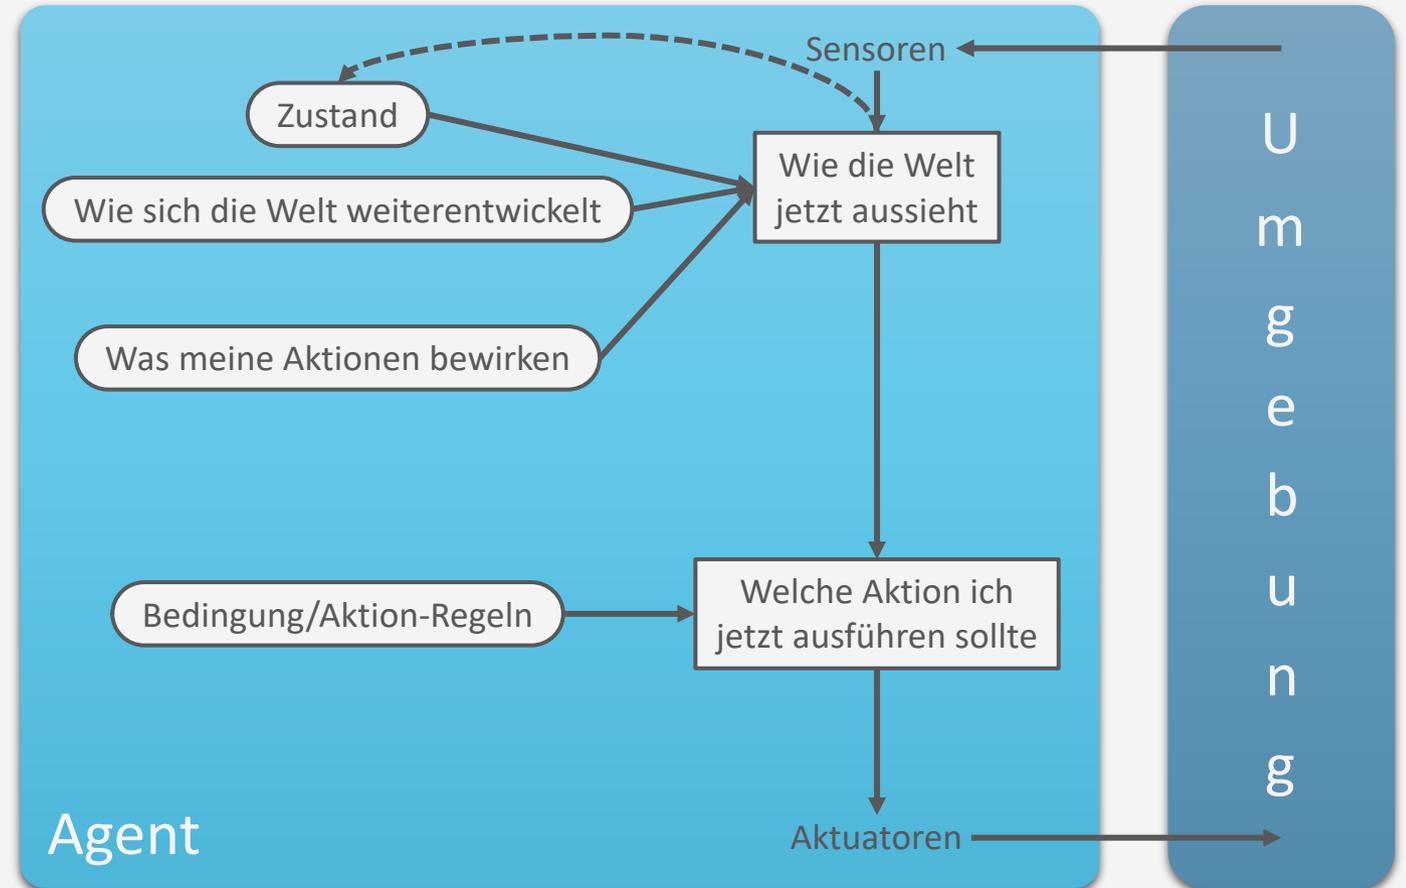
- Beispiel Saugroboter

```
function REFLEX-VACUUM-AGENT([location, status]) returns eine Aktion

  if status = Schmutzig then return Saugen
  else if location = A then return Rechts
  else if location = B then return Links
```

## Agentenstruktur: Modellbasierter Reflexagent

- Bei teilweiser Beobachtbarkeit, nicht sichtbaren Teil verfolgen
  - Mittels **internen Zustand**
    - Vom Wahrnehmungsverlauf abhängig
    - Nicht beobachtbare Aspekte des aktuellen Zustandes widerspiegeln
      - Kodierung der Umgebung: atomar, faktorisiert oder strukturiert
- Aktualisierung des internen Zustands mit Informationen über
  - Weiterentwicklung der Umgebung unabhängig vom Agenten
  - Auswirkungen der Aktionen auf die Umgebung



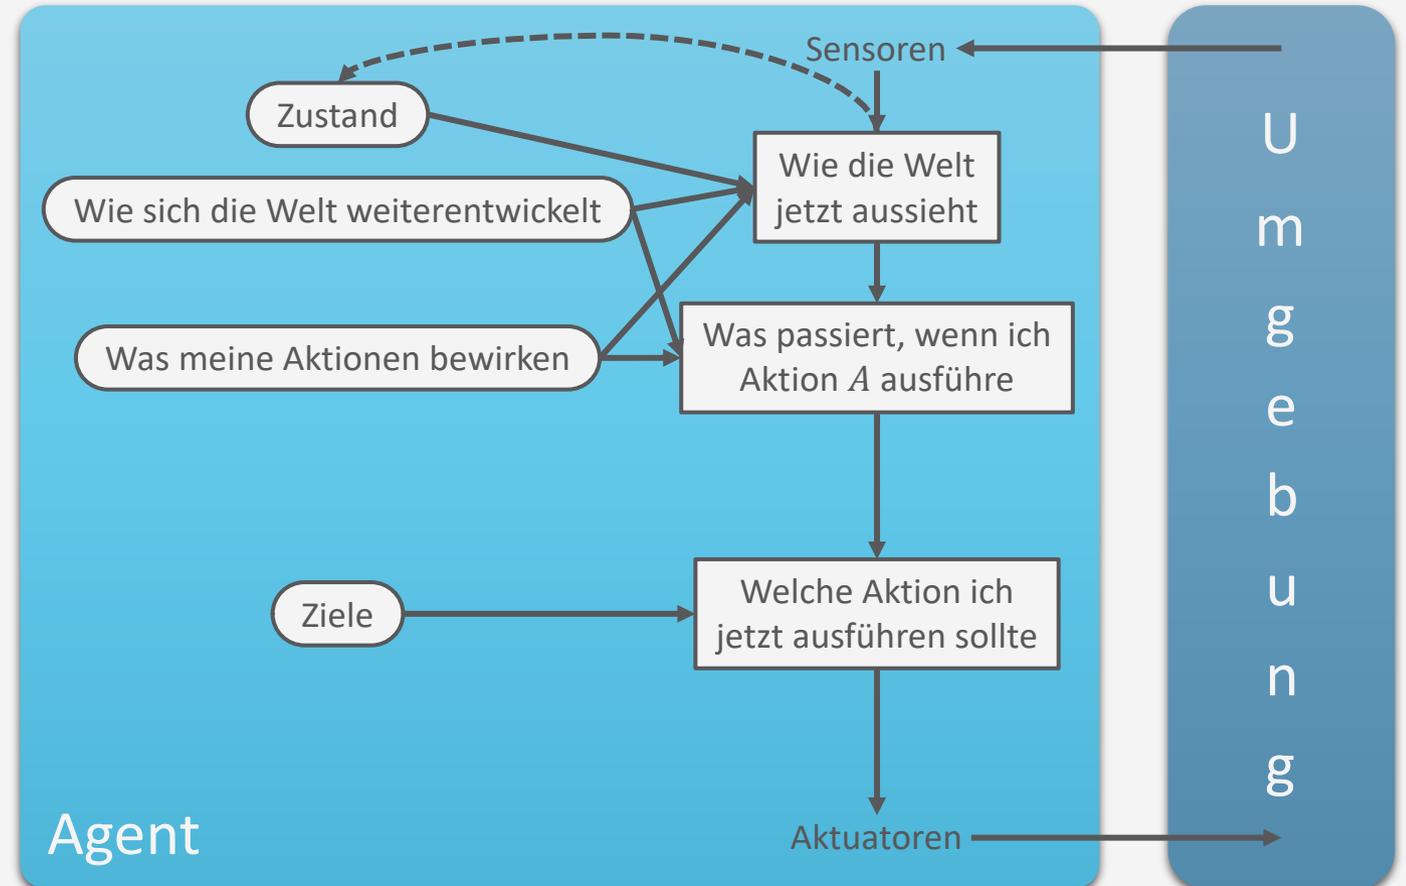
# Implementierung eines modellbasierten Agenten

```
function MODEL-BASED-REFLEX-AGENT(percept) returns eine Aktion
  persistent: state, die aktuelle Vorstellung des Agenten vom Zustand der Welt
               model , eine Beschreibung, wie der nächste Zustand vom
               aktuellen Zustand und der Aktion abhängt
               rules, eine Menge von Bedingungs-Aktions-Regeln
               action, die vorherige Aktion, anfangs keine

  state ← UPDATE-STATE(state, action, percept, model)
  rule ← RULE-MATCH(state, rules)
  action ← rule.ACTION
  return action
```

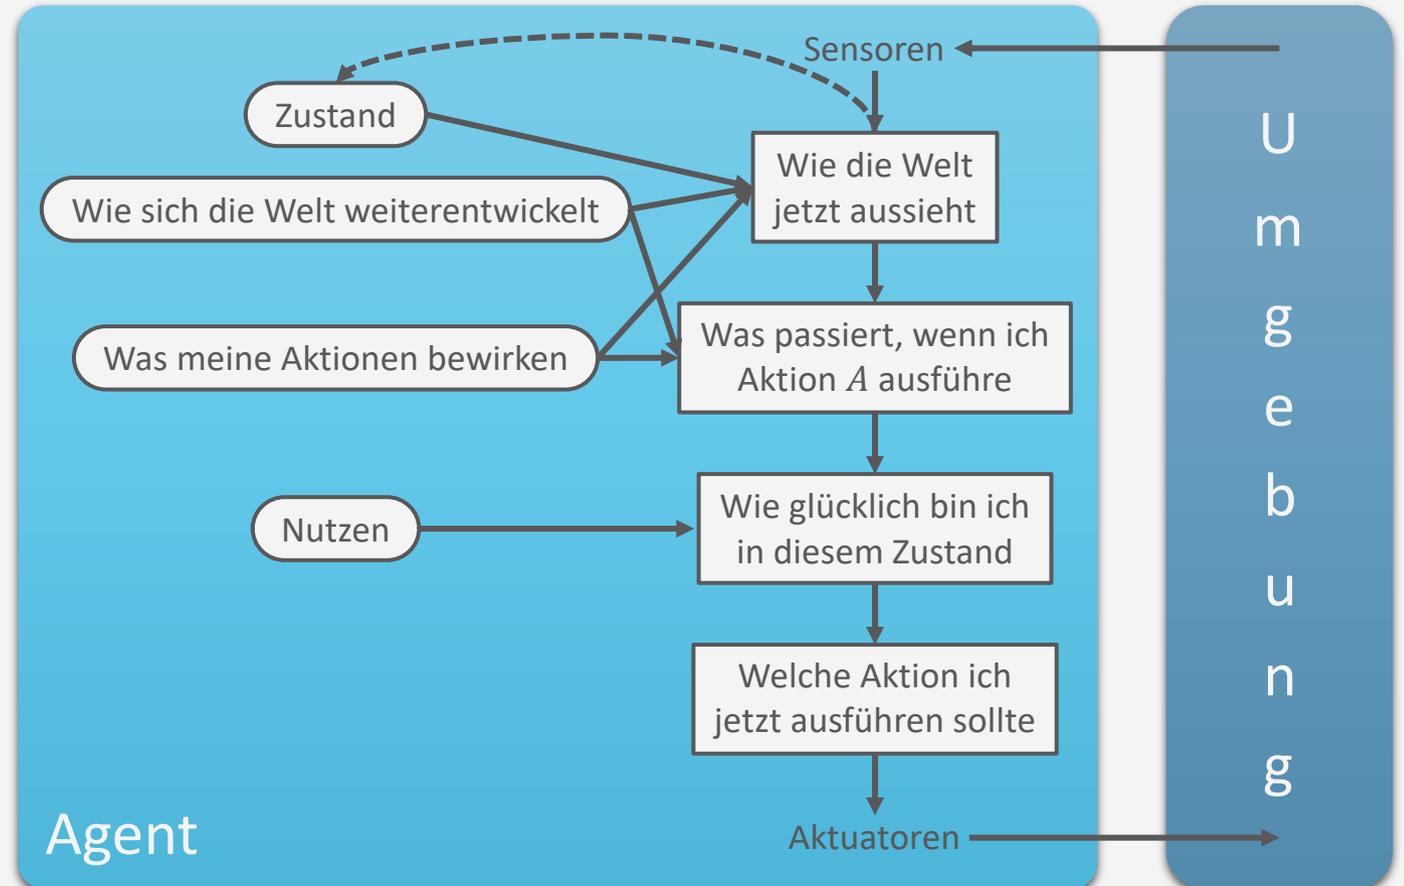
## Agentenstruktur: Modell- & Zielbasierter Agent

- Zielinformation nützlich
  - Beschreibung wünschenswerter Zustände
    - Abzuleiten vom Leistungskriterium
    - Bedingungen, die ein Zustand erfüllen muss
    - Beispiel Saugroboter  
 $\forall x \in Pos : x = sauber$
- Aktuelle Zustandsbeschreibung und Zielinformation kombinieren, um Aktionen auszuwählen, die zum Ziel führen



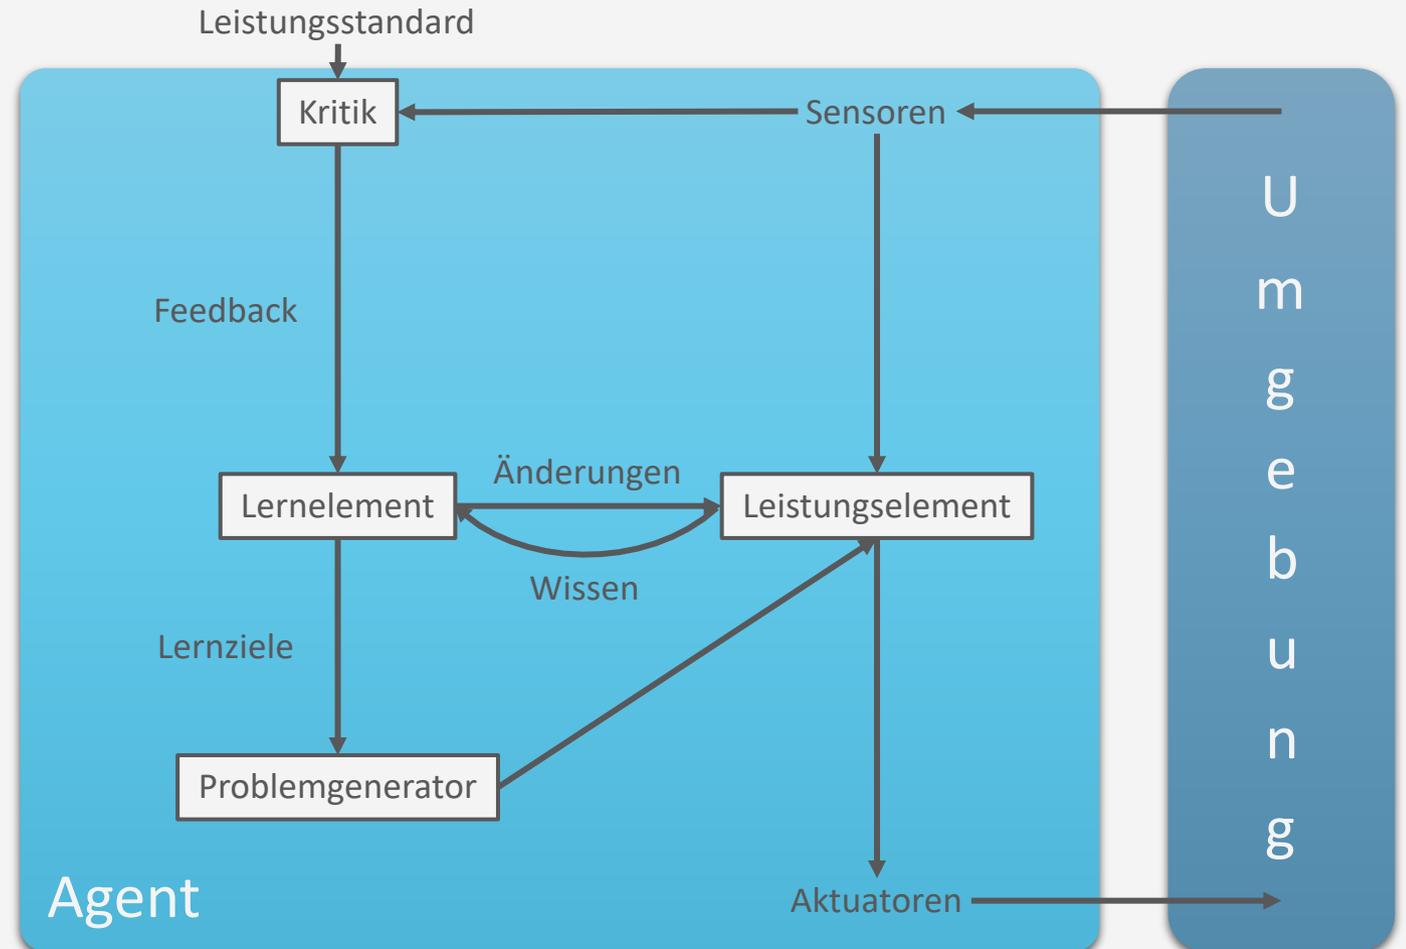
## Agentenstruktur: Modell- & Nutzenbasierter Agent

- Zielbasiert: binäre Unterscheidung zwischen *glücklich* und *unglücklich*
- Nutzen als Verteilung über mögliche Zustände
  - Werden wir in *PGMs* nutzen
  - Quasi Internalisierung der Leistungsbewertung
    - Wenn interne Nutzenfunktion = externe Leistungsbewertung:
    - Dann ist ein Agent, der Aktionen auswählt, um seinen Nutzen zu maximieren, *rational* entsprechend der externen Leistungsbewertung



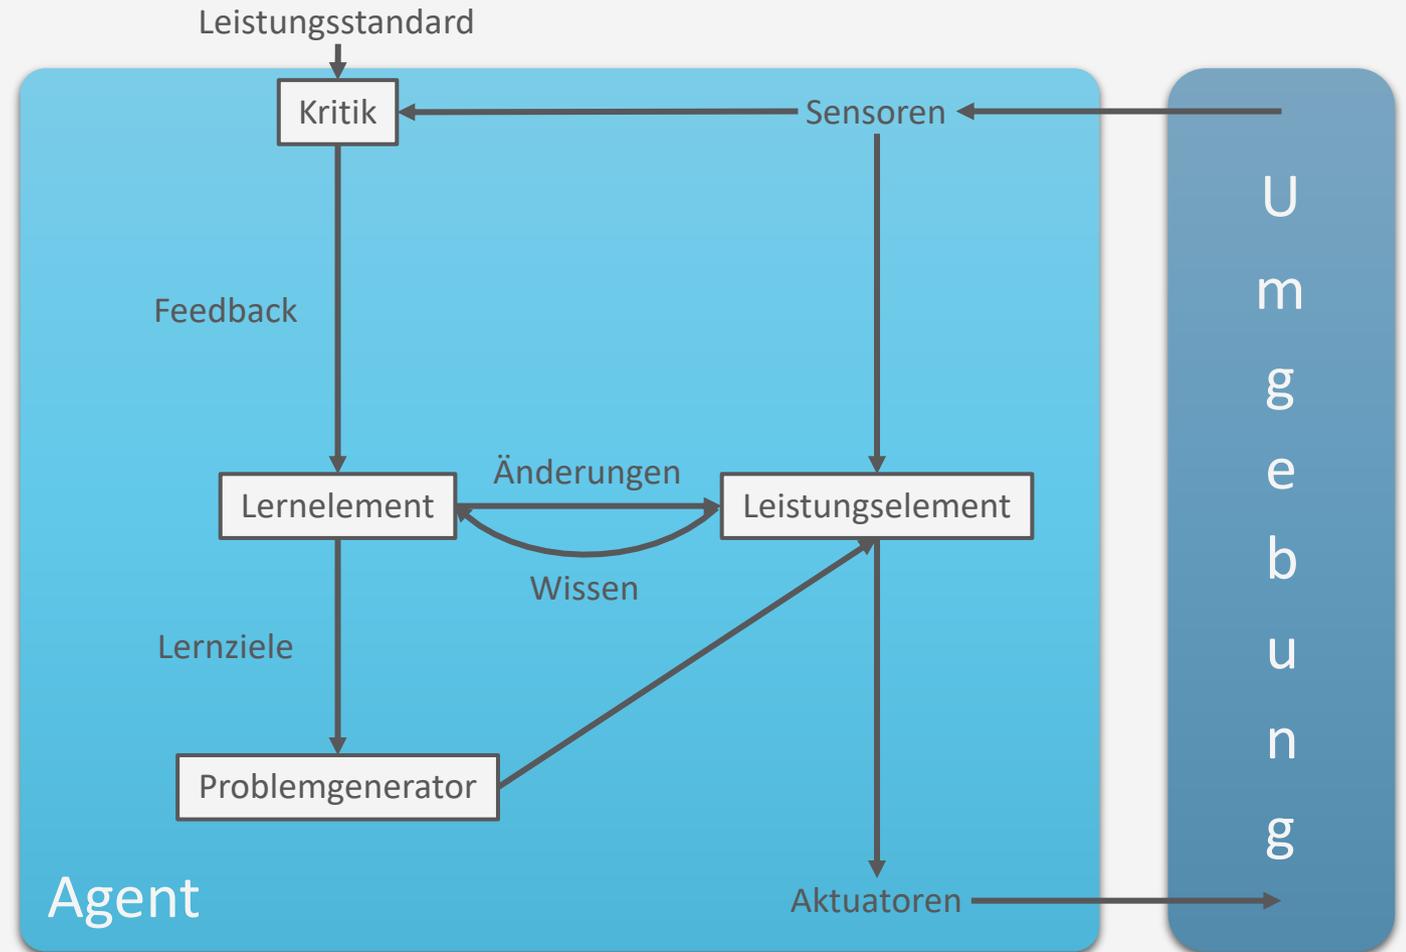
## Agentenstruktur: Lernender Agent

- Bisher: Agenten fallen Entscheidungen über Aktionen
- Woher die Agentenprogramme nehmen?
  - Zu aufwendig per Hand zu erstellen
- Lernenden Agenten erstellen und lernen lassen
  - Erlaubt in zunächst unbekannter Umgebung zu arbeiten und kompetenter zu werden
  - Forschungsgebiet: *Reinforcement Learning*



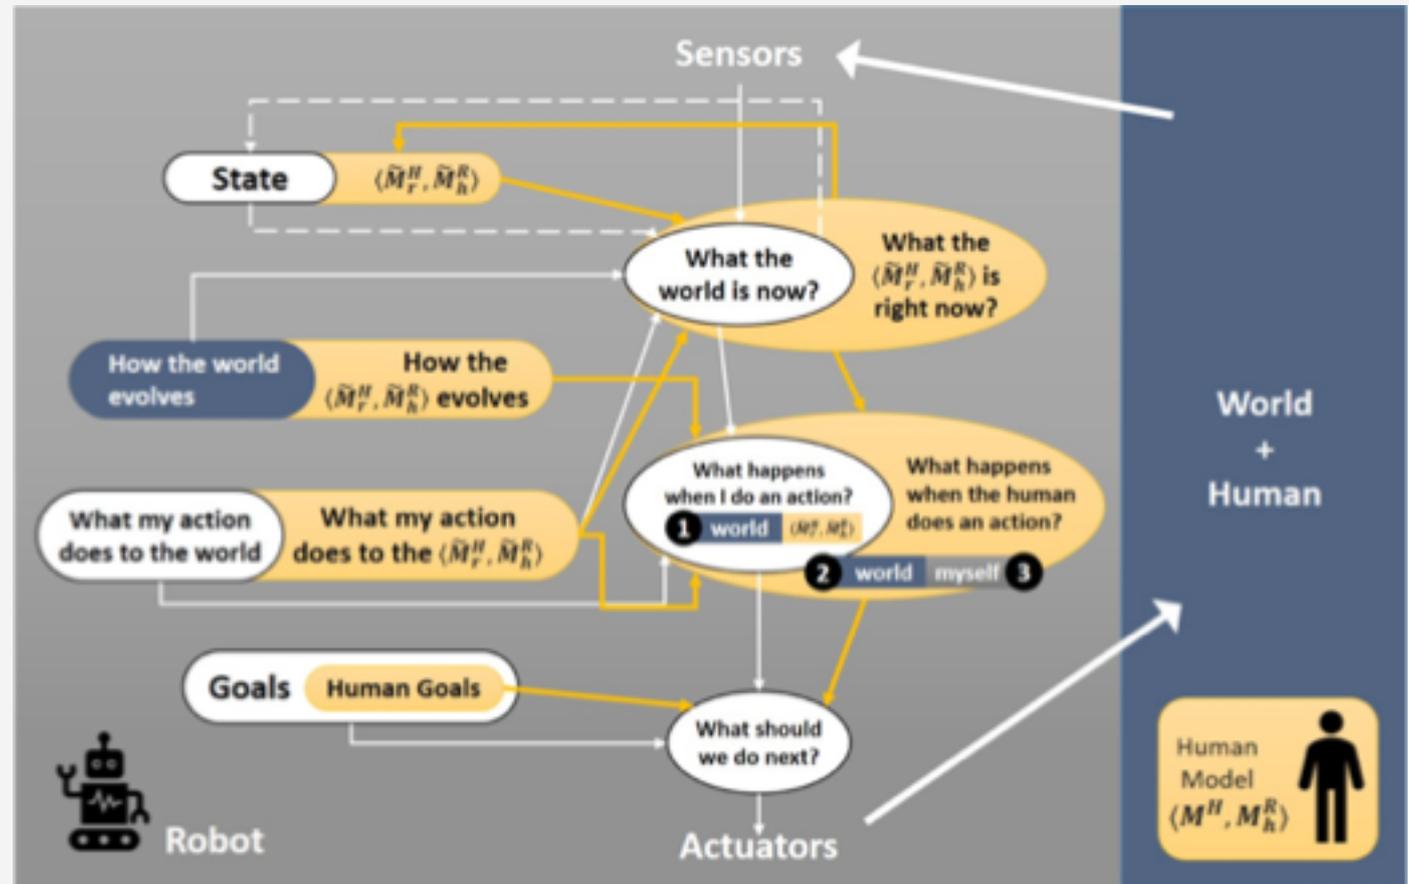
## Agentenstruktur: Lernender Agent

- 4 konzeptuelle Komponenten
  - Lernelement
    - Verbesserungen erzielen
  - Leistungselement (bisheriger Agent)
    - Auswahl externer Aktionen
- Kritik
  - Feedback zu Ergebnissen
  - Vom Lernelement verwendet um Änderungen am Leistungselement zu entscheiden
- Problemgenerator (zur Exploration)
  - Aktionen vorschlagen, die zu neuen und informativen Erfahrungen führen



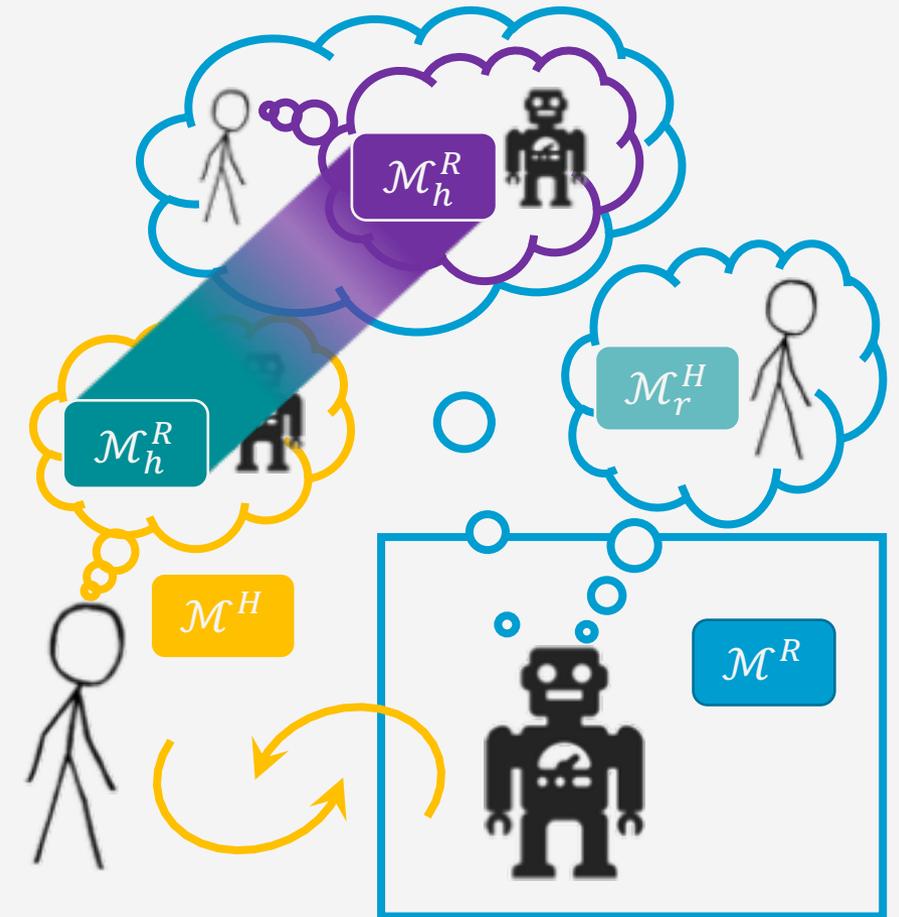
## Hinweis: Aktuelle Forschung

- Mensch-bewusster Agent (*human-aware agent*)
  - Interaktion mit einem Menschen während des Handelns
  - Beispiel: *Urban Search and Rescue* mittels Roboter
- Vorhandene Modelle:
  - Eigentliches Agentenmodell  $\mathcal{M}^R$
  - Modell des Menschen  $\mathcal{M}^H$
  - Agentenmodell  $\tilde{\mathcal{M}}_r^H$  von  $\mathcal{M}^H$
  - Agentenmodell  $\tilde{\mathcal{M}}_h^R$  von  $\mathcal{M}_h^R$ , dem Modell, das der Mensch von  $\mathcal{M}^R$  hat



## Hinweis: Aktuelle Forschung

- Vorhandene Modelle:
  - Eigentliches Agentenmodell  $\mathcal{M}^R$
  - Modell des Menschen  $\mathcal{M}^H$
  - Agentenmodell  $\tilde{\mathcal{M}}_r^H$  von  $\mathcal{M}^H$
  - Agentenmodell  $\tilde{\mathcal{M}}_h^R$  von  $\mathcal{M}_h^R$ , dem Modell, das der Mensch von  $\mathcal{M}^R$  hat
- $\tilde{\mathcal{M}}_r^H$  erlaubt menschliches Verhalten zu antizipieren
- $\tilde{\mathcal{M}}_h^R$  erlaubt menschliche Erwartungen zu erfüllen
- Siehe z.B. Subbarao (Rao) Kambhampati  
<http://rakaposhi.eas.asu.edu>



## Zwischenzusammenfassung

- Tabellenbasierter Agent
- Einfacher Reflexagent
  - Bedingung/Aktionen-Regeln
- Modellbasierter Agent
  - Interner Zustand, Aktualisierung bzgl. Veränderung der Umgebung selbst & Auswirkungen von Aktionen
- Modell- & zielbasierter Agent
  - Zielinformation
- **Modell- & nutzenbasierter Agent**
  - Zufriedenheit / Nutzen von Zuständen
- Lernender Agent um einen handelnden Agenten zu lernen und stetig zu verbessern
- Aktuelle Forschung: mensch-bewusster Agent
  - Modellierung der angenommenen Auffassung der Umgebung durch den Menschen

Blau markiert:  
Umsetzung mittels PGMs  
in dieser Vorlesung

# Inhalte

## 1. Künstliche Intelligenz & Agenten

- Agentenabstraktion, Rationalität
- Aufgabenumgebung

## 2. Episodische PGMs

- Gerichtetes Modell: Bayes Netze (BNs)
- Ungerichtete Modelle

## 3. Exakte Inferenz in episodischen PGMs

- Wahrscheinlichkeits- und Zustandsanfragen
- Direkt auf den Modellen, mittels Hilfsstrukturen

## 4. Approximative Inferenz in episodischen PGMs

- Wahrscheinlichkeitsanfragen
- Deterministische, stochastische Algorithmen

## 5. Lernalgorithmen für episodische PGMs

- Bei (nicht) vollständigen Daten, (un)bekannter Struktur

## 6. Sequentielle PGMs und Inferenz

- Dynamische BNs, Hidden-Markov-Modelle
- filtering / prediction / hindsight Anfragen, wahrscheinlichste Zustandssequenz
- Exakter, approximativer Algorithmus

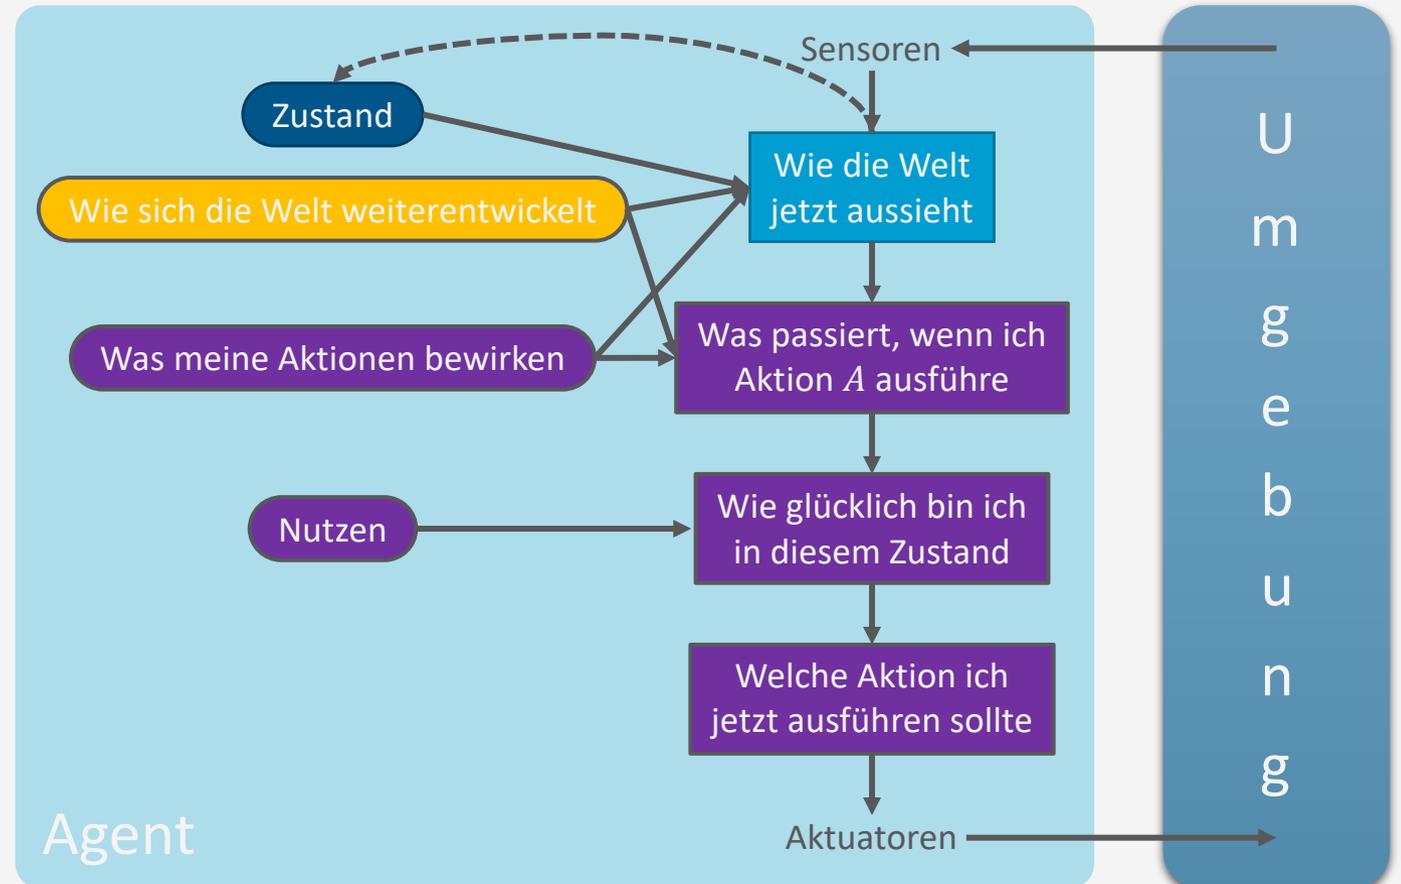
## 7. Entscheidungstheoretische PGMs

- Präferenzen, Nutzenprinzip
- PGMs mit Entscheidungs- und Nutzenknoten
- Berechnung der besten Aktion (Aktionssequenz)

## 8. Abschlussbetrachtungen

## Einordnung der Vorlesung: *Modell- und nutzenbasierter Agent*

- Nachfolgende Themen der Vorlesung
  2. Episodische PGMs
  3. Exakte Inferenz in episodischen PGMs
  4. Approximative Inferenz in episodischen PGMs
  5. Lernalgorithmen für episodische PGMs
  6. **Sequentielle PGMs und Inferenz**
  7. Entscheidungstheoretische PGMs



# Überblick: 1. Künstliche Intelligenz & Agenten

## A. *Was ist KI?*

- Menschliches und rationales Denken & Handeln

## B. *Agenten*

- Agentenabstraktion
- Eigenschaften

## C. *Aufgabenumgebung*

- PEAS
- Eigenschaften

## D. *Agentenstruktur*

- Reflexiv, modellbasiert, zielbasiert, nutzenbasiert, lernend

→ Episodische PGMs