INF FAKULTÄT FÜR INFORMATIK

Intelligente Systeme

Erweiterungen der Fähigkeiten eines Agenten

Prof. Dr. R. Kruse C. Braune C. Moewes

{kruse,cmoewes,russ}@iws.cs.uni-magdeburg.de

Institut für Wissens- und Sprachverarbeitung
Fakultät für Informatik
Otto-von-Guericke Universität Magdeburg

Erweiterung der Fähigkeiten von Agenten

bisher: S-R-Agenten mit unmittelbarer Reaktion auf Sensorreize
jetzt: Ausnutzung von Sensorinformationen aus Vergangenheit

Übersicht

1. **Temporale Informationen**
   Beispiel: Roboter in Gitterwelt
2. **Räumliche Informationen**
3. **Informationsfusion**
4. **Problemlösung**

Integration von zeitlichen Informationen

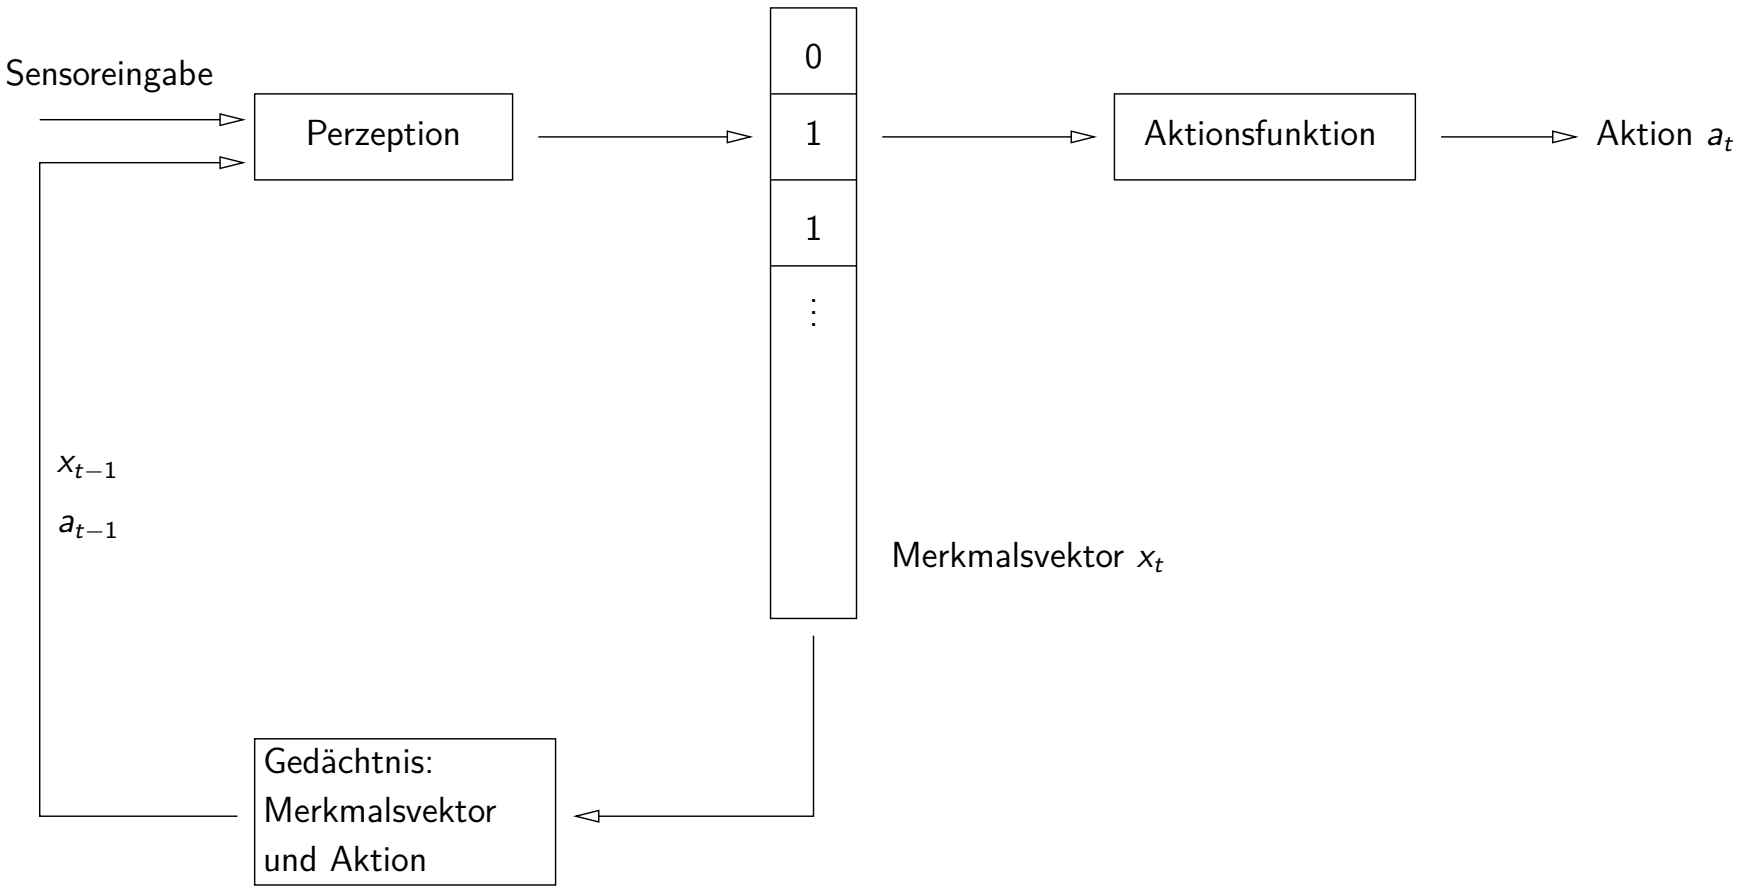

Zustandsagenten (erweitert)

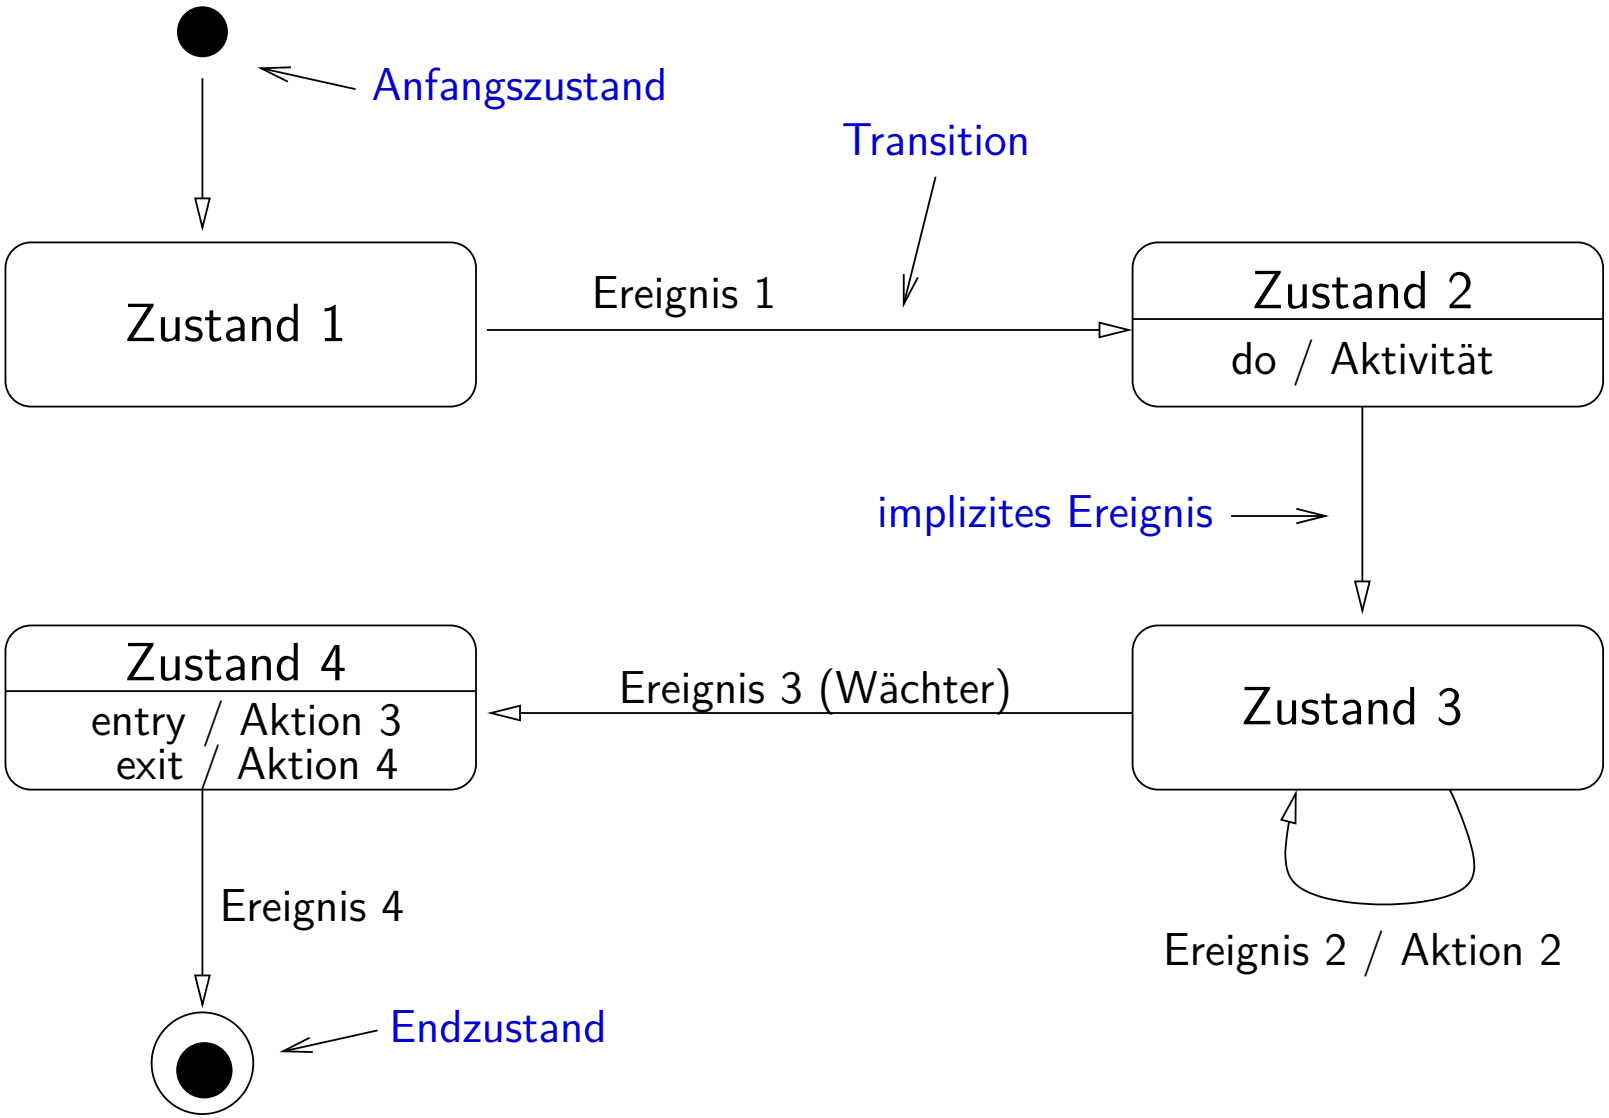

Beispiel: Roboter in Gitterwelt (1)

Roboter in Gitterwelt mit begrenzter Sensorinformation

- Sensoreingabe zum Zeitpunkt t:
  - s_2^t, s_4^t, s_6^t, s_8^t (d.h. nur 4 statt bisher 8 Sensoren)
  - $s_i^t = 1 \leftrightarrow$ Feld s_i^t ist nicht frei
- Aufgabe: Wandverfolgung
- Idee: nutze Merkmalsvektor des jeweils vorherigen Zeitpunkts

Beispiel: Roboter in Gitterwelt (2)

Definition der Merkmalsvektoren:

- $w_i^t = s_i^t$ für $i = 2, 4, 6, 8$
- $w_1^t = 1 \leftrightarrow w_2^{t-1} = 1$ and $a_{t-1} = \text{east}$
- $w_3^t = 1 \leftrightarrow w_4^{t-1} = 1$ and $a_{t-1} = \text{south}$
- $w_5^t = 1 \leftrightarrow w_6^{t-1} = 1$ and $a_{t-1} = \text{west}$
- $w_7^t = 1 \leftrightarrow w_8^{t-1} = 1$ and $a_{t-1} = \text{north}$

$\Rightarrow$ (teilweiser) Ausgleich eingeschränkter Sensorinformationen möglich!

Beispiel: Roboter in Gitterwelt (3)

Sinnvolle Aktionen zur Wandverfolgung:

- $w_2^t \wedge \neg w_4^t \rightarrow$ east
- $w_4^t \wedge \neg w_6^t \rightarrow$ south
- $w_6^t \wedge \neg w_8^t \rightarrow$ west
- $w_8^t \wedge \neg w_2^t \rightarrow$ north
- $w_1^t \wedge \neg w_2^t \rightarrow$ north
- $w_3^t \wedge \neg w_4^t \rightarrow$ east
- $w_5^t \wedge \neg w_6^t \rightarrow$ south
- $w_7^t \wedge \neg w_8^t \rightarrow$ west
- alle $w_i = 0 \rightarrow$ north

Beispiel: Roboter in Gitterwelt (4)

Implementierung (Beispiel einer Bewegung):

	Sensoreingabe				Merkmalsvektor								Aktion
t	s_2^t	s_4^t	s_6^t	s_8^t	w_1^t	w_2^t	w_3^t	w_4^t	w_5^t	w_6^t	w_7^t	w_8^t	a_t
0	1	0	0	0	0	1	0	0	0	0	0	0	east
1	1	0	0	0	1	1	0	0	0	0	0	0	east
2	1	1	0	0	1	1	0	1	0	0	0	0	south
2'	*0*	*0*	*0*	*0*	*1*	*0*	*0*	*0*	*0*	*0*	*0*	*0*	*north*

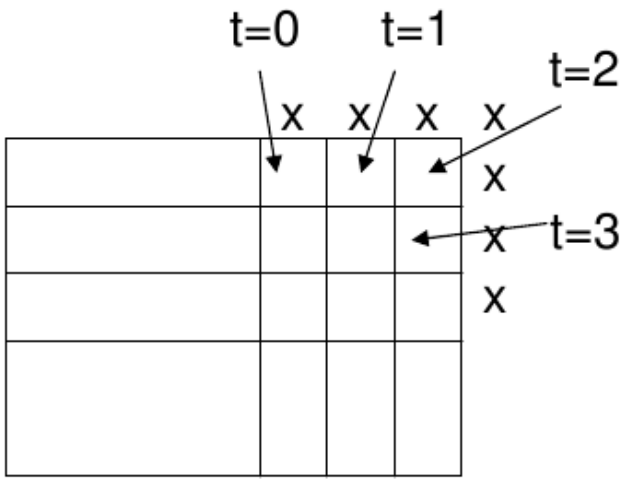

Anmerkung: Situation t=2‘ z.B. bei Sensorstörung (alle Sensoren s_i=0)

Einfache RNNs: Elman-Netze

- Einführung einer Kontextschicht
- ermöglicht Speichern von Informationen

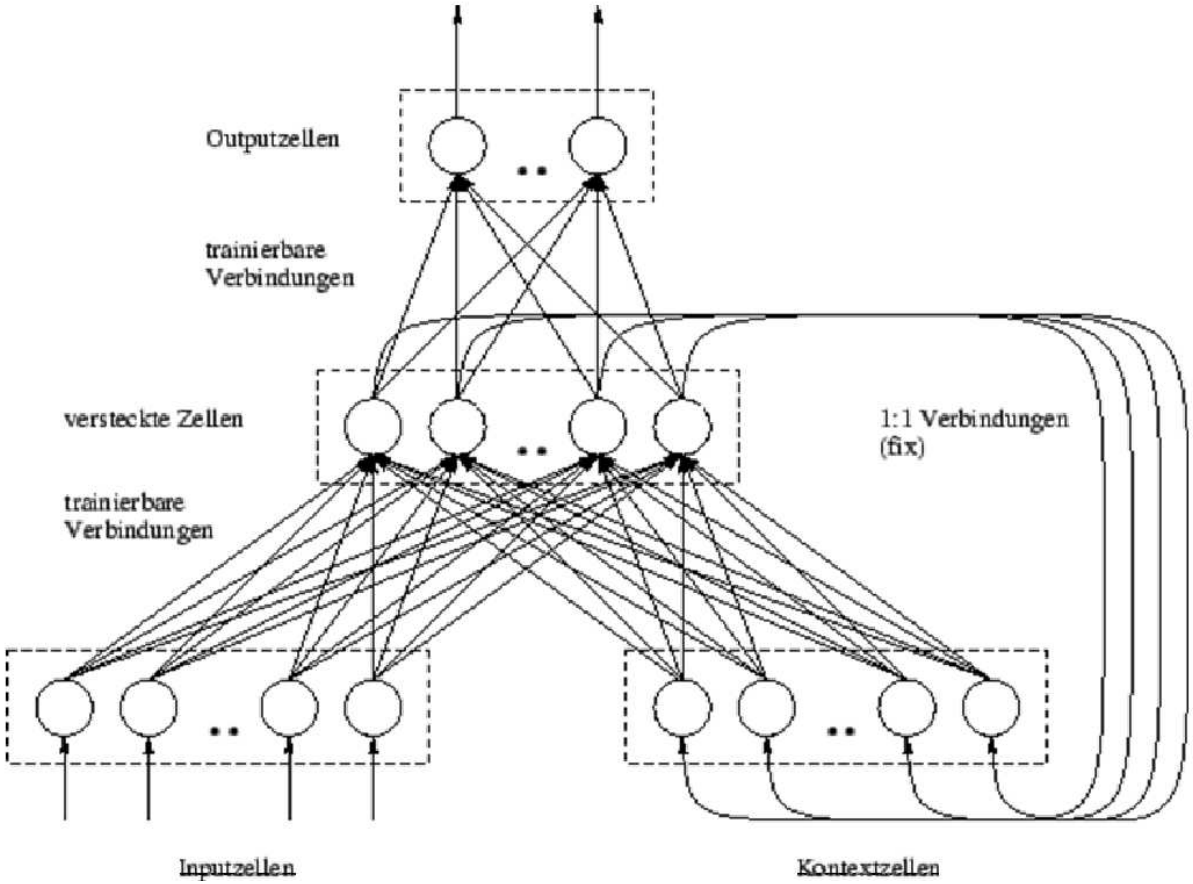

Beispiel: Elman-Netz für Roboter

Elman-Netz für Roboter in Gitterwelt:

- 8-dimensionale Merkmalsvektoren (i.A. Anzahl der Dimensionen unbekannt)
- 4 Eingaben (Sensoren)
- 4 Ausgaben (Richtungen; Ausgabe mit größtem Wert wird gewählt)
- Training durch Backpropagation
- „lernfähige“ Automaten

Beispiel: Elman-Netz für Roboter

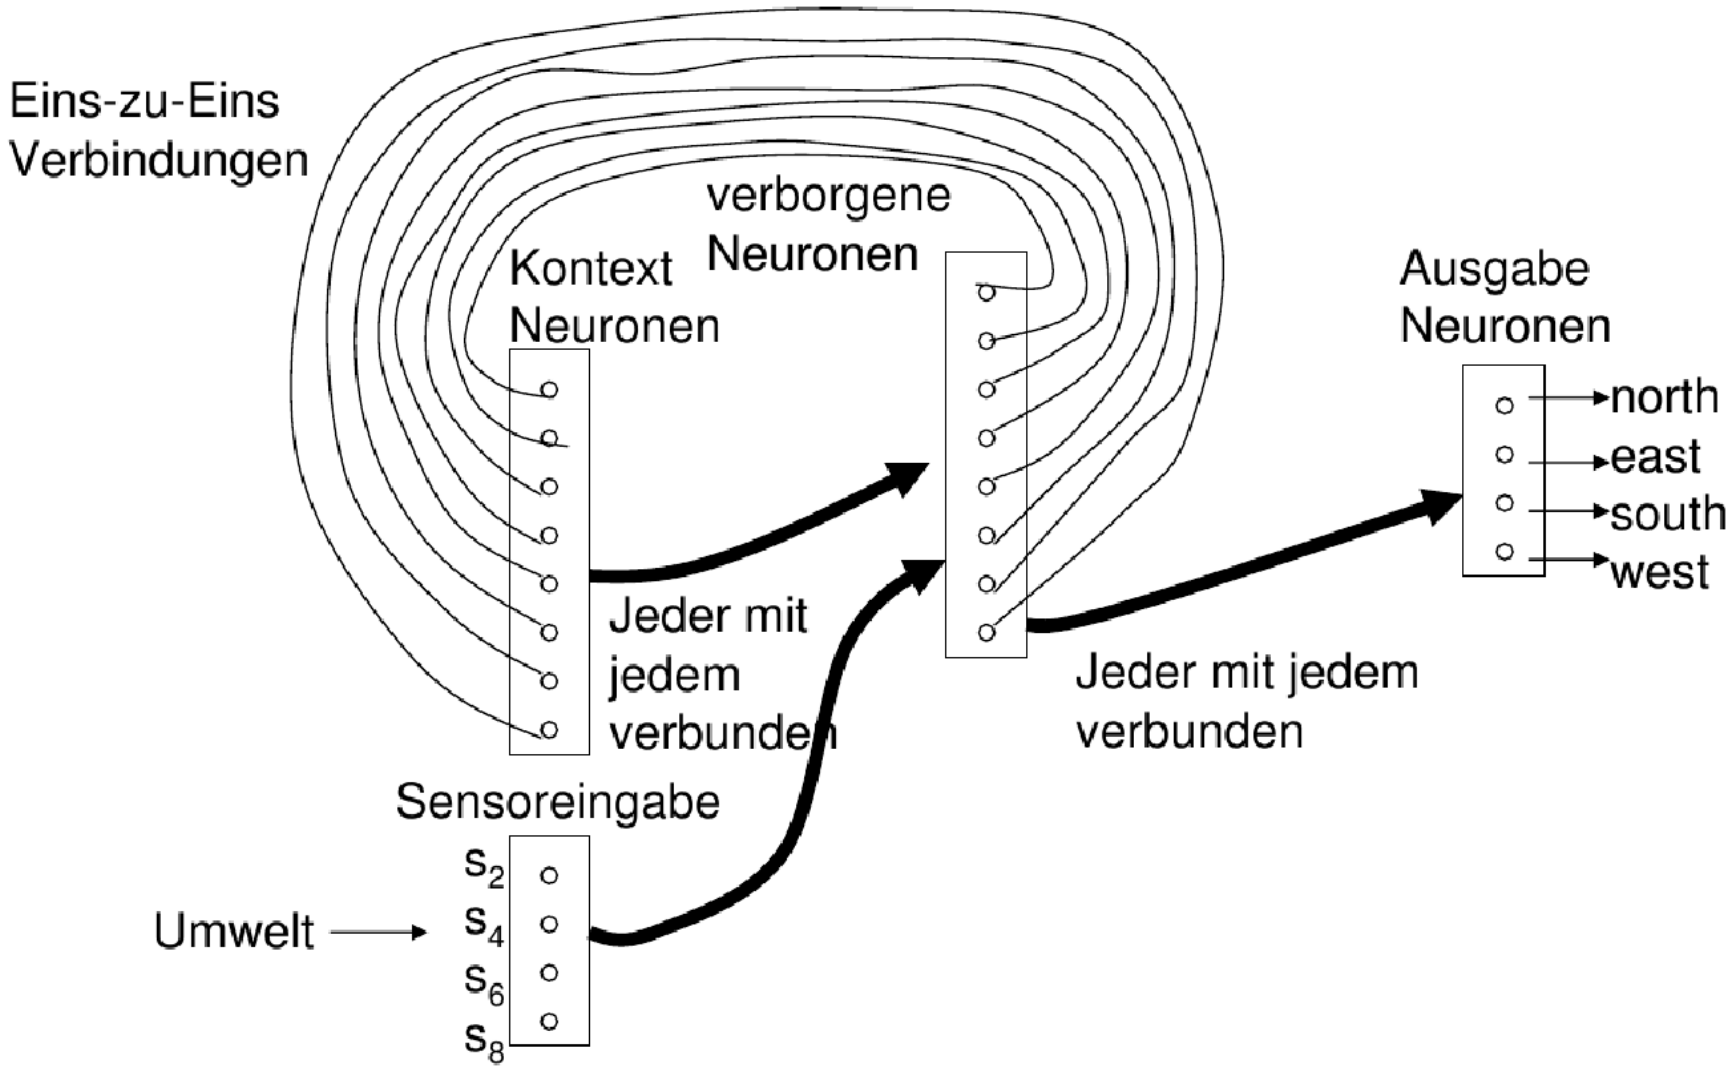

Übersicht

1. Temporale Informationen

2. Räumliche Informationen

3. Informationsfusion

4. Problemlösung

Integration von räumlichen Informationen

bisher: nur Informationen über einen sehr kleinen Umgebungsausschnitt:

- unmittelbare Nachbarschaft
- gespeichert in Merkmalsvektor

Idee der Umgebungsmodelle:

- Speicherung möglichst aller bereits gesammelter Informationen über Umgebung
- Nutzung geeigneter Datenstrukturen wie z.B. Landkarten

Beispiel: Umgebungsmodell für Gitterwelt (1)

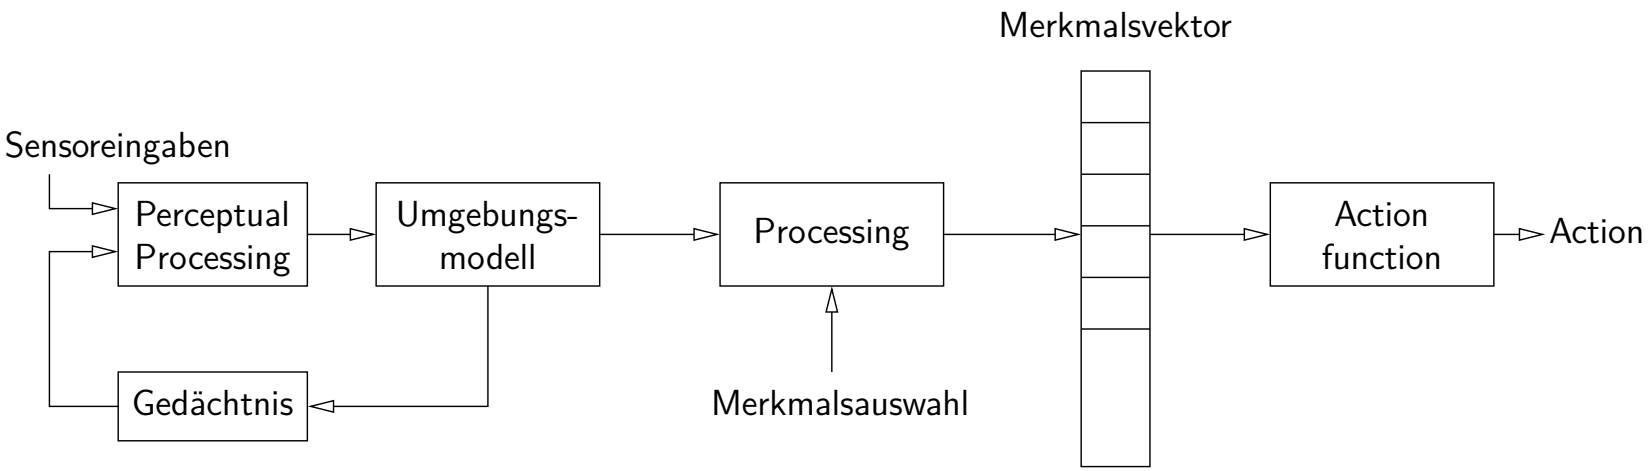

Beispiel: Umgebungsmodell für Gitterwelt (2)

1	1	1	1	1	?	?
1	0	0	0	0	0	?
1	0	0	0	0	0	?
1	0	0	R	0	0	?
1	0	0	0	0	0	?
1	?	?	?	?	?	?
?	?	?	?	?	?	?

- 1: belegt, 0: frei, ?: unbekannt, R: Roboter
- mögliche Aktion basierend auf Informationen: *go west (or north)* and follow wall

Umgebungsmodelle: Aktionen

- Aktionen z.B. über zwei-dimensionale Potentialfelder bestimmen
- Potentialfelder: Überlagerung von anziehenden (“attractive”) und abstoßenden (“repulsive”) Komponenten
- Bewegung des Roboters: absteigender Richtung des Gradienten (lokale Minima!)
- Bewegungsrichtung: vorberechnet oder online (z.B. in sich ändernden Umgebungen)

Umgebungsmodelle: Potentialfeld für Gridworld

anziehende Komponente:

- durch Zielfeld erzeugt: $p_a(x^{(\rho)}) = k_1 \cdot d(x^{(\rho)})^2$
- k_1: konstanter Faktor, d: Abstand zum Zielfeld

abstoßende Komponente(n):

- durch Hindernisse erzeugt: $p_r(x^{(\rho)}) = \frac{k_2}{d(x^{(\rho)})^2}$
- wobei k_2 konstanter Faktor, d Abstand zum Hindernis

insgesamt: $p = p_a + p_r$

Potentialfelder: Beispielumgebung

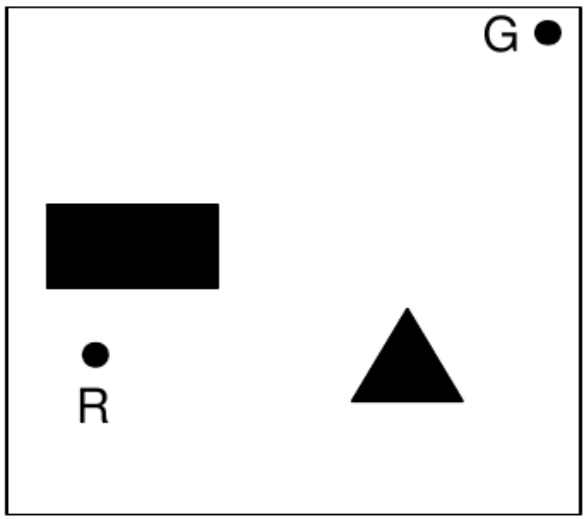

Roboter (R)

Ziel (G)

Hindernisse (♦)

Potentialfelder: Potentialfeldkomponenten

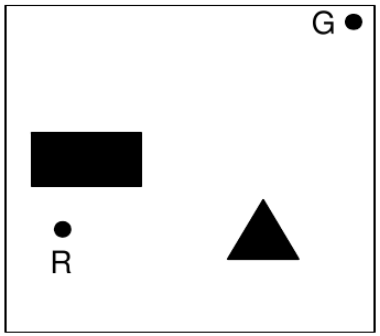

Roboter (R)

Ziel (G)

Hindernisse (♦)

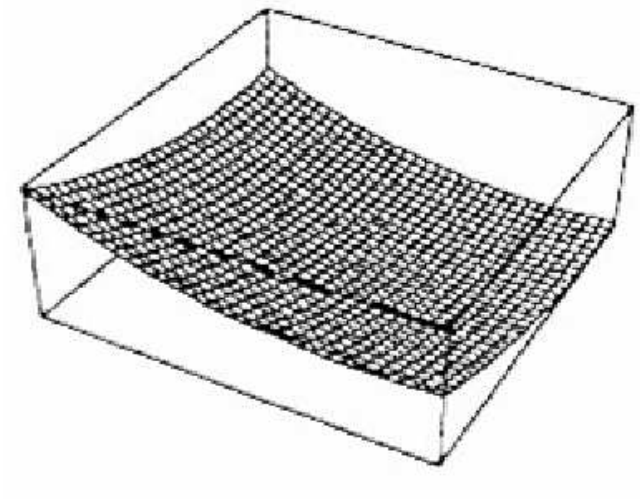

Ziel

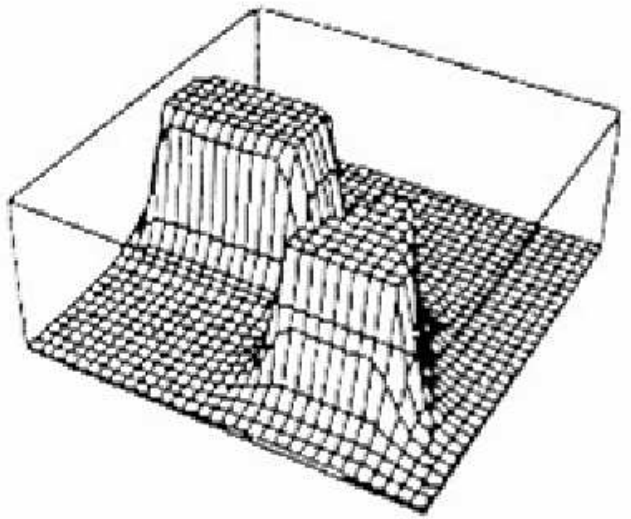

Hindernisse

Potentialfelder: Gesamtes Potentialfeld

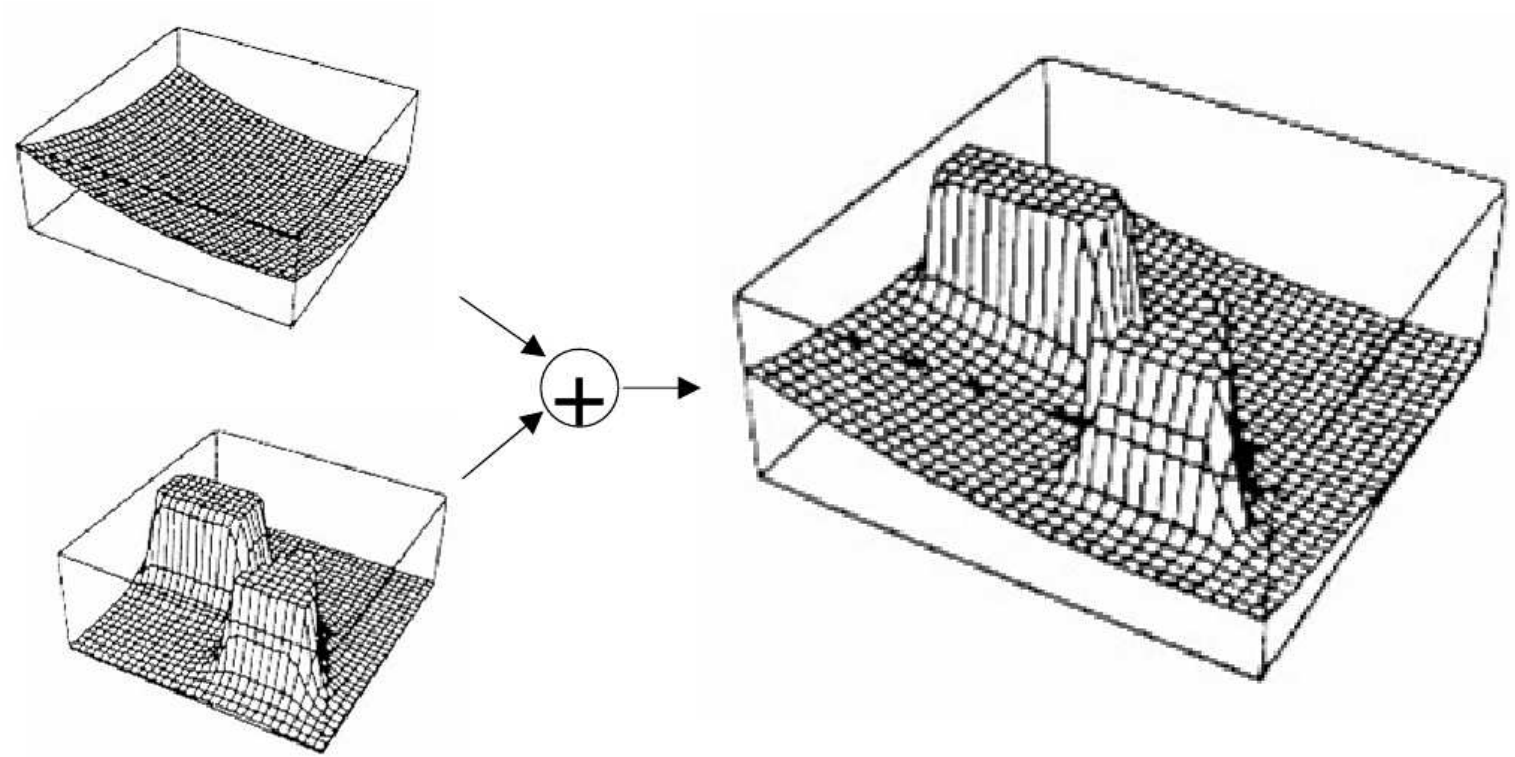

Äquipotentiallinien (für Gradientenverfahren)

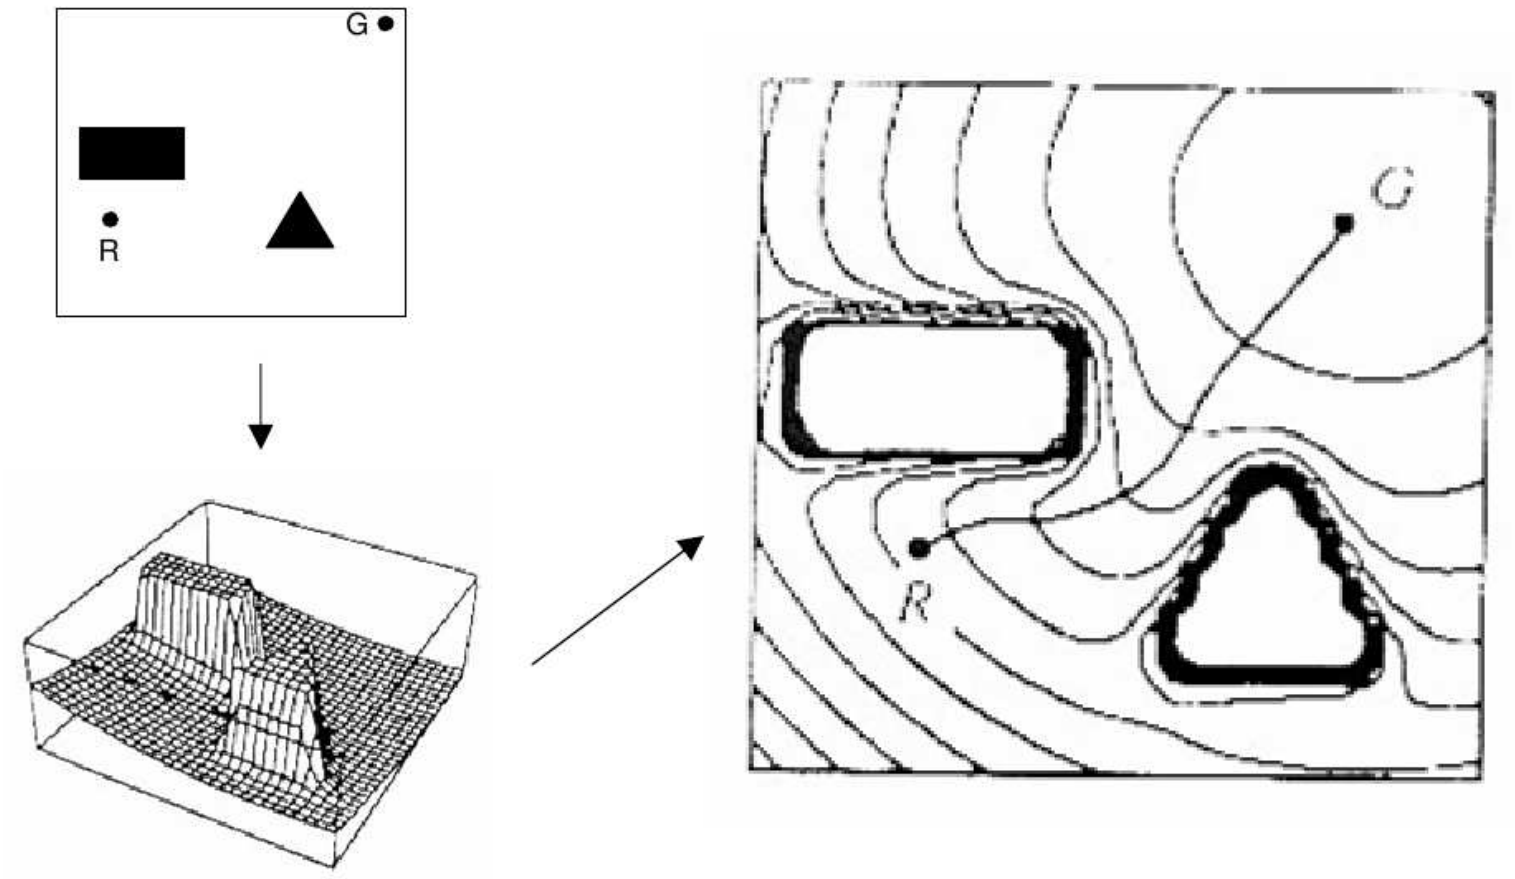

Übersicht

1. Temporale Informationen

2. Räumliche Informationen

3. **Informationsfusion**

4. Problemlösung

Beispiel: Blackboard-Systeme

- Blackboard: Spezielle Datenstruktur
- Knowledge Source (KS): Programm zum Lesen und Schreiben des Blackboards

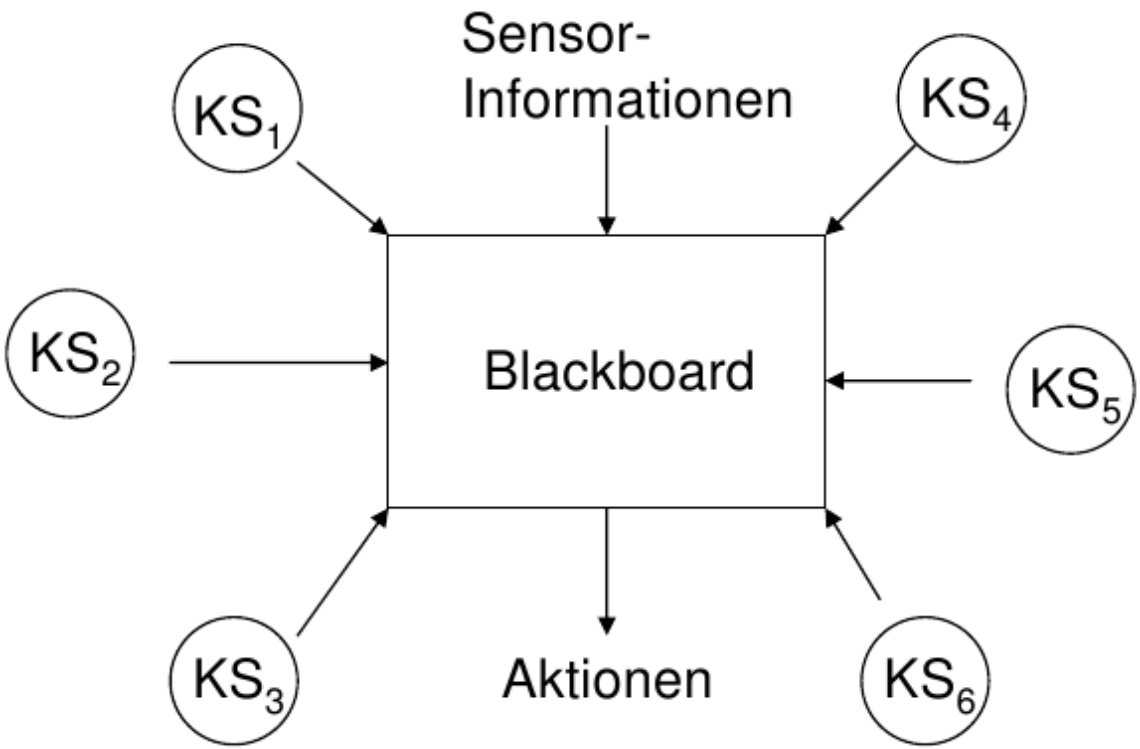

Blackboard-Systeme: Knowledge Source

Bestandteile:

1. Bedingungsteil (berechnet Wert eines Merkmals)
2. Aktionsteil (Programm zum Lesen/Schreiben des Blackboards und/oder zum Ausführen externer Aktionen)

- *Konfliktlöser* entscheidet bei Ausführung von zwei KS, welche gewählt wird
- KS = „Experte“ eines Teils des Blackboards, den es überwacht

Blackboard-Systeme: Beispiel (1)

- Weltmodell im Roboter: kann unvollständig/falsch sein (Grund: Sensorfehler)
- mögliche Knowledge Sourcen:
  - Lückenfüller (Gap Filler): sucht nach engen Räumen (tight spaces) im gelernten Umgebungsmodell und markiert Feld bzw. korrigiert ggf. vorhandene Fehler
  - Sensorfilter (Sensory Filter): vergleicht Sensorinformationen mit gelerntem Umgebungsmodell und versucht Fehler zu beseitigen

Blackboard-Systeme: Beispiel (2)

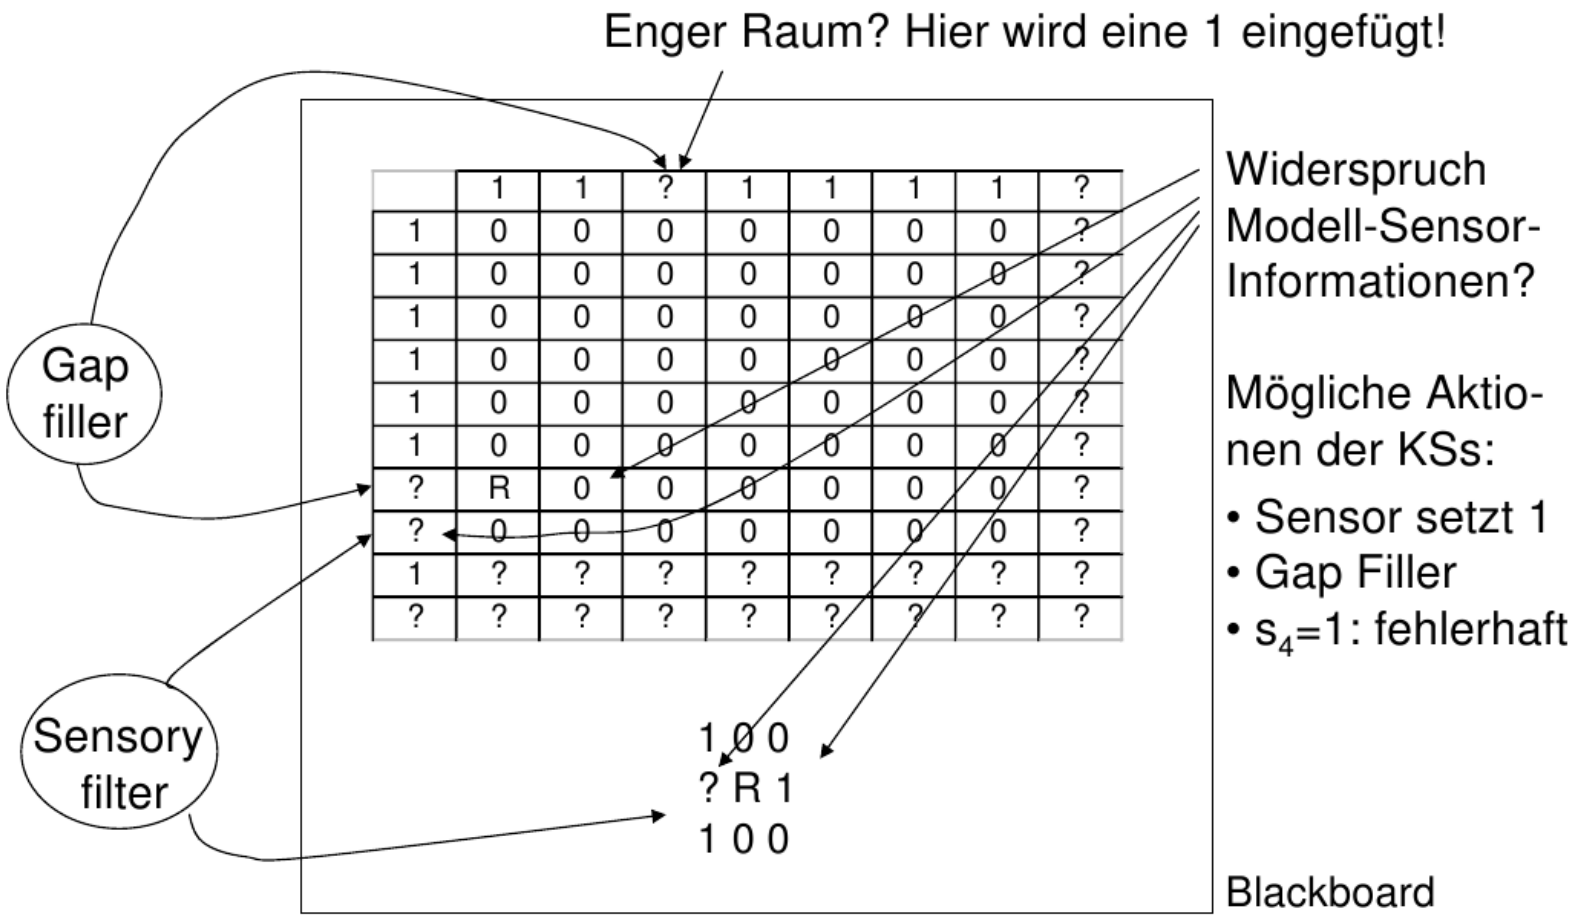

	1	1	?	1	1	1	1	?
1	0	0	0	0	0	0	0	?
1	0	0	0	0	0	0	0	?
1	0	0	0	0	0	0	0	?
1	0	0	0	0	0	0	0	?
1	0	0	0	0	0	0	0	?
1	0	0	0	0	0	0	0	?
?	R	0	0	0	0	0	0	?
?	0	0	0	0	0	0	0	?
1	?	?	?	?	?	?	?	?
?	?	?	?	?	?	?	?	?

Übersicht

1. Temporale Informationen

2. Räumliche Informationen

3. Informationsfusion

4. Problemlösung

Problemlösende Agenten

SIMPLE-PROBLEM-SOLVING-AGENT

Eingabe: Wahrnehmung *percept*

Ausgabe: eine Aktion *action*

```
 1: static seq: Aktionssequenz (anfangs leer)
 2: static state: momentane Beschreibung der Welt
 3: static goal: Ziel (anfangs null)
 4: static problem: Problembeschreibung
 5: state ← UPDATE-STATE(state, percept)
 6: if seq is empty {
 7:     goal ← FORMULATE-GOAL(state)
 8:     problem ← FORMULATE-PROBLEM(state, goal)
 9:     seq ← SEARCH(problem)
10: }
11: action ← RECOMMENDATION(seq, state)
12: seq ← Remainder(seq, state)
13: return action
```

Beispiel: Routenplanung

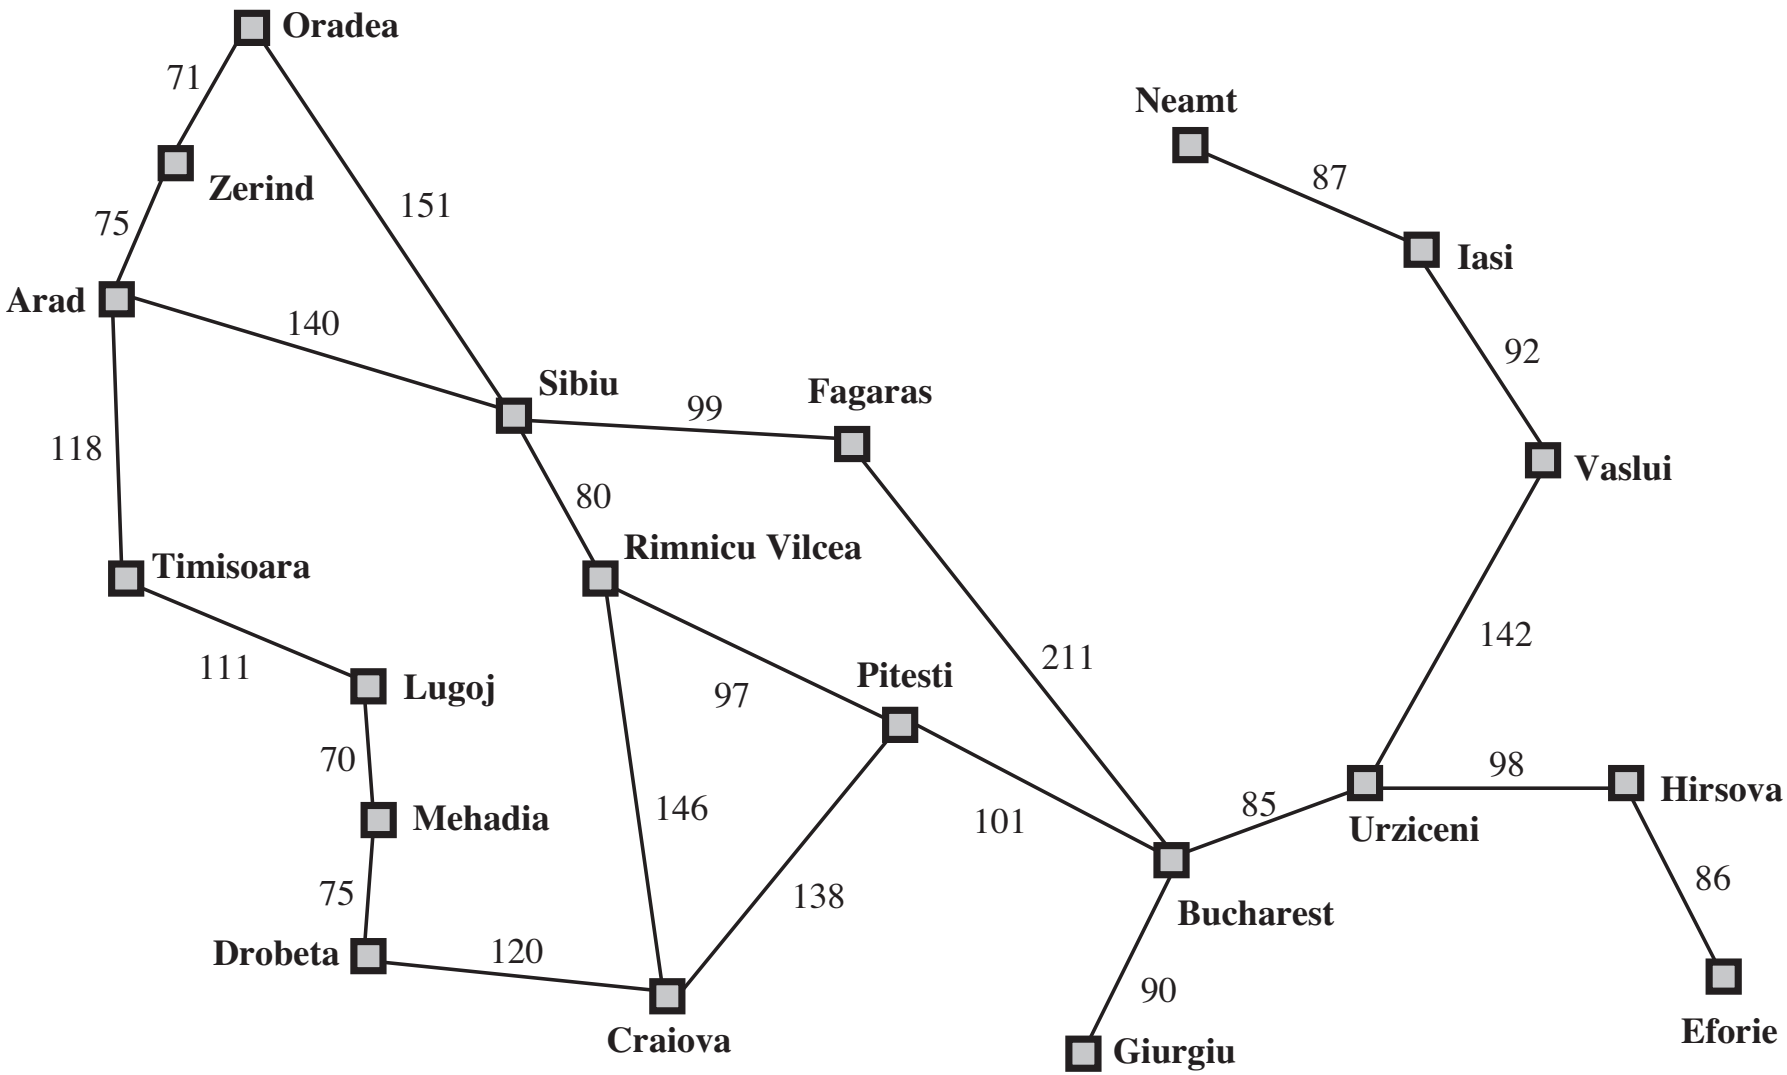

Arten von Problemen

deterministisch (vollständig beobachtbar)

- Agent weiß genau in welchem Zustand er sein wird
- Lösung ist eine Sequenz von Aktionen

nicht beobachtbar $\Rightarrow$ **konformantes Problem**

- Agent hat u.U. keine Ahnung in welchem Zustand er sich befindet
- Lösung (falls existent) ist eine Sequenz von Aktionen

nichtdeterministisch (teilw. beobachtbar) $\Rightarrow$ **Zufallsproblem**

- Wahrnehmungen: neue Infos über momentan Zustand
- Lösung: ungewisser Plan oder Strategie
- oftmals hängen Suche und Ausführung voneinander ab

unbekannter Zustandsraum $\Rightarrow$ **Explorationsproblem** ("online")

- Wissen über einen bestimmten Teil des Zustandsraum kann durch Suchverfahren maximiert werden
- ein klares Ziel, das zu erreichen wäre, gibt es nicht

Staubsaug-Welt

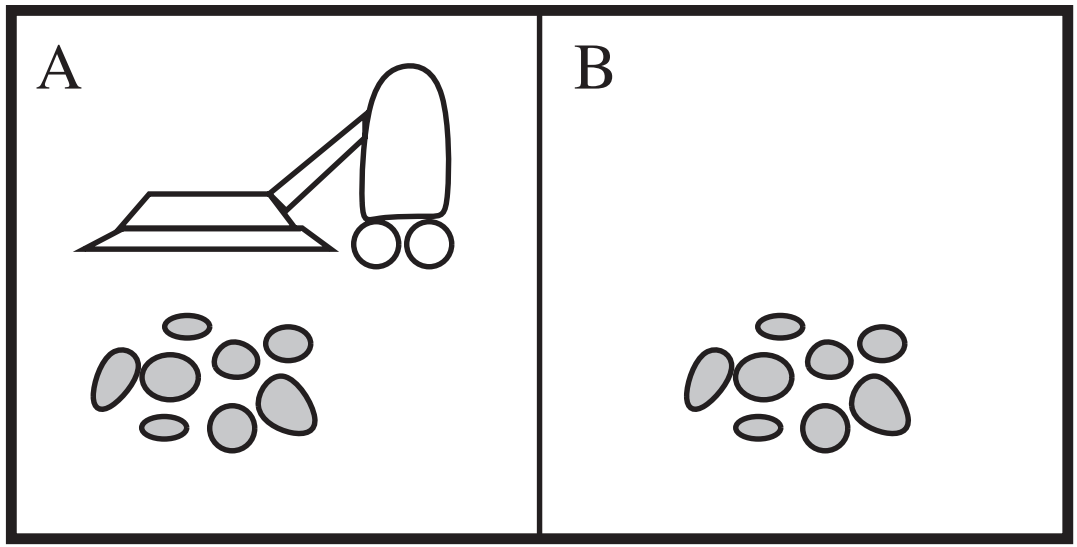

Wahrnehmung: Ort und Status, z.B. [*A*, *Dirty*]
Aktionen: *Left*, *Right*, *Suck*, *NoOp*

Ein Staubsaug-Agent

Sequenz von Wahrnehmungen	Aktion
[*A*, *Clean*]	*Right*
[*A*, *Dirty*]	*Suck*
[*B*, *Clean*]	*Left*
[*B*, *Dirty*]	*Suck*
[*A*, *Clean*], [*A*, *Clean*]	*Right*
[*A*, *Clean*], [*A*, *Dirty*]	*Suck*
⋮	⋮

REFLECTIVE-VACUUM-AGENT

```
1: if staus = Dirty {
2:     return Suck
3: } else {
4:     if location = A {
5:         return Right
6:     } else {
7:         return Left
8:     }
9: }
```

Beispiel: Staubsaug-Welt

unterschiedliche Lösungen durch unterschiedliche Probleme:

deterministisch: Start in Zustand #5,
Lösung: [*Right*, *Suck*]

konformant

- Start in Zustand # $\{1, 2, 3, 4, 5, 6, 7, 8\}$
  z.B. *Right* nach $\{2, 4, 6, 8\}$
- Lösung: [*Right*, *Suck*, *Left*, *Suck*]

Zufall

- Start in Zustand #5
- Murphys Gesetz: *Suck* könnte einen sauberen Teppich beschmutzigen!
- lokale Abtastung: auch vom Schmutz
- Lösung: [*Right*, if *dirt* then *Suck*]

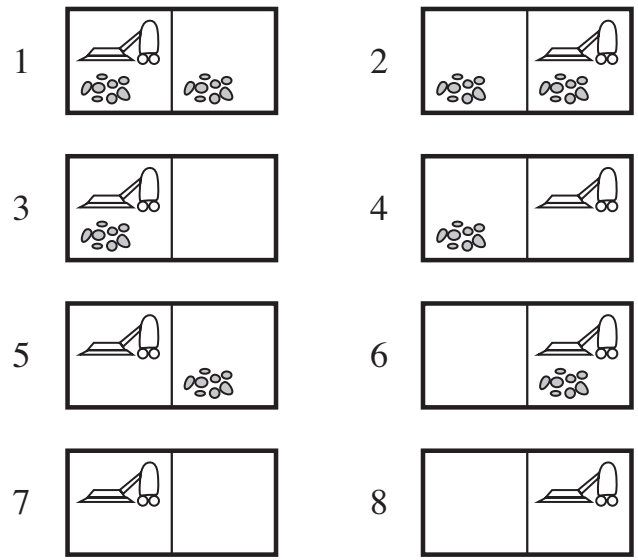

Ansatz für deterministische Probleme

ein **Problem** sei definiert durch 4 Begriffe

1. **Anfangszustand**, z.B. *Arad*
2. **Nachfolgerfunktion** $S(x)$ = Menge aller Aktions-Zustands-Paare, z.B. $S(Arad) = \{\langle Arad \rightarrow Zerind, Zerind\rangle, \ldots\}$
3. **Zieltest**
   - explizit, z.B. $x = Bukarest$
   - implizit, z.B. $NoDirt(x)$
4. **Wegkosten** (zusätzlich)
   - Summe der Abstände, Anzahl ausgeführter Aktionen, etc.
   - $c(x, a, y)$ seien Schrittkosten mit ≥ 0

dann ist eine **Lösung** eine Sequenz von Aktionen vom Anfangs- bis zum Endzustand

Beispiel: Zustandsgraph der Staubsaug-Welt

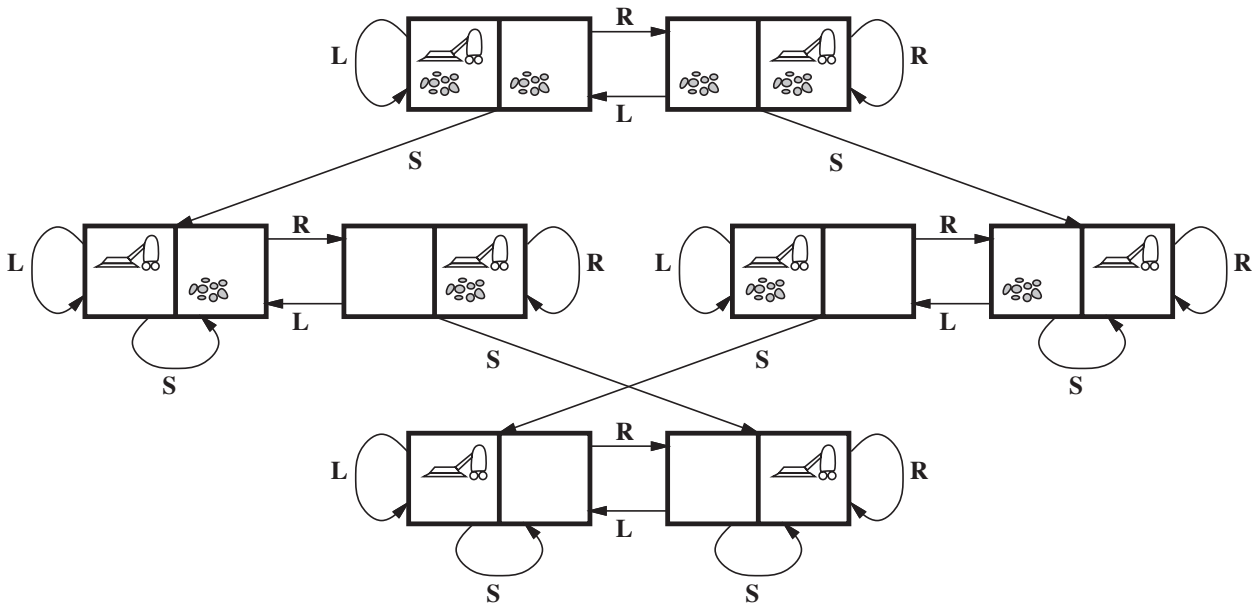

- Zustände: ganzzahliger Schmutz und Ort des Agenten
- Aktionen: *Left*, *Right*, *Suck*, *NoOp*
- Zieltest: kein Schmutz
- Pfadkosten: 1 pro Aktion (0 für *NoOp*)

Beispiel: Das 8-Puzzle

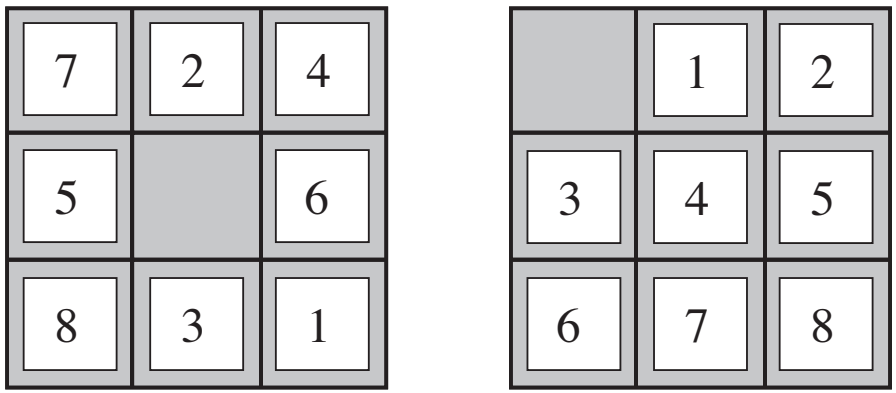

Start State Goal State

- Zustände: ganzzahlige Positionen der Plättchen
- Aktionen: bewege Lücke *links*, *rechts*, *hoch*, *runter*
- Zieltest: Zielzustand (gegeben)
- Pfadkosten: 1 pro Zug

Hinweis: optimale Lösung der n-Puzzle-Familie ist NP-schwer

Implementierung: Zustände vs. Knoten

- Zustand = physikalische Konfigurierung
- Knoten = Datenstruktur (Teil eines Suchbaums mit Eltern, Kinder, Tiefe, Pfadkosten $g(x)$)
- Zustände haben keine Eltern, Kinder, Tiefe, oder Pfadkosten $g(x)$

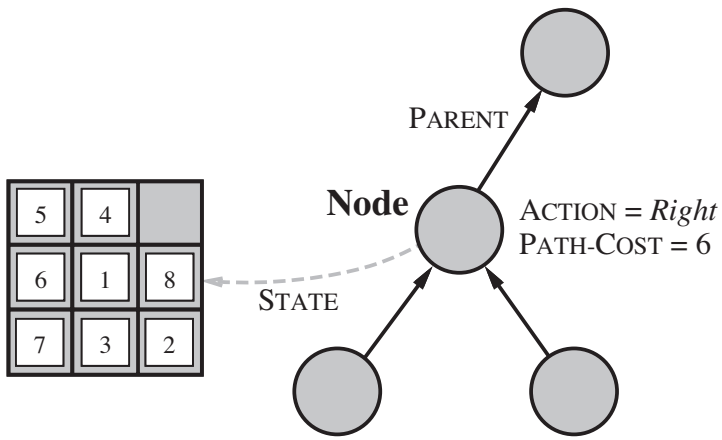

- EXPAND-Funktion erzeugt neue Knoten
- SUCCESSOR-Funktion erzeugt zugehörige Zustände

Implementierung: Generelle Baumsuche

TREE-SEARCH

Eingabe: Problembeschreibung *problem*, Rand *fringe*
Ausgabe: Lösung oder Fehler

```
 1: seq ← INSERT(MAKE-NODE(INITIAL-STATE[problem]), fringe)
 2: while true {
 3:     if fringe is empty {
 4:         return failure
 5:     }
 6:     node ← REMOVE-FRONT(fringe)
 7:     if GOAL-TEST(problem, STATE(node)) {
 8:         return node
 9:     }
10:     fringe ← INSERT-ALL(EXPAND(node, problem), fringe)
11: }
```

Implementierung: Generelle Baumsuche

EXPAND

Eingabe: Knoten *node*, Problembeschreibung *problem*
Ausgabe: eine Menge von Knoten

```
 1: for each action, result in SUCCESSOR(problem, STATE[node]) {
 2:     s ← new NODE
 3:     PARENT-NODE[s] ← node
 4:     ACTION[s] ← action
 5:     STATE[s] ← result
 6:     PATH-COST[s] ← PATH-COST[node] + STEP-COST(node, action, s)
 7:     DEPTH[s] ← DEPTH[node] + 1
 8:     add s to successors
 9: }
10: return successors
```

Problemlösung durch geeignete Suche

Suchstrategie = Reihenfolge der Expansion von Nachfolgerknoten
Bewertung anhand von

- Vollständigkeit: Wird immer 1 Lösung gefunden falls eine existiert?
- Zeitkomplexität: Anzahl der Knoten erzeugt/expandiert
- Speicherkomplexität: maximale Anzahl von Knoten im Speicher
- Optimalität: Wird immer 1 Lösung mit geringsten Kosten gefunden?

Zeit- und Speicherkomplexität gemessen anhand von

- b maximaler Verzweigungsfaktor des Suchbaums
- d Tiefe der Lösung mit geringsten Kosten
- m maximale Tiefe des Zustandsraums (eventuell ∞)