

RUB



INSTITUT
FÜR
NEUROINFORMATIK

Reinforcement Learning

Abdullah Sahin

27.11.2018

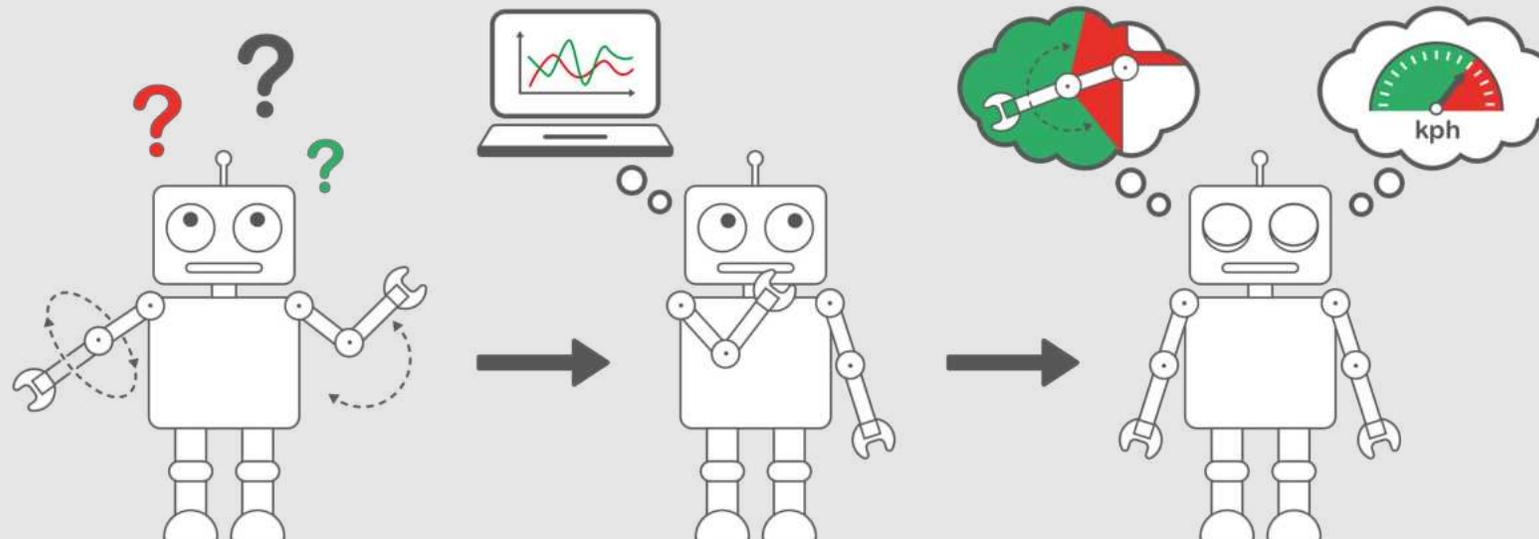
- **Supervised Learning**
 - erfordert gelabelte Trainingsdaten

- *Unsupervised Learning*
 - erfordert Interpretation der Ausgabe

- **Supervised Learning**
 - erfordert gelabelte Trainingsdaten

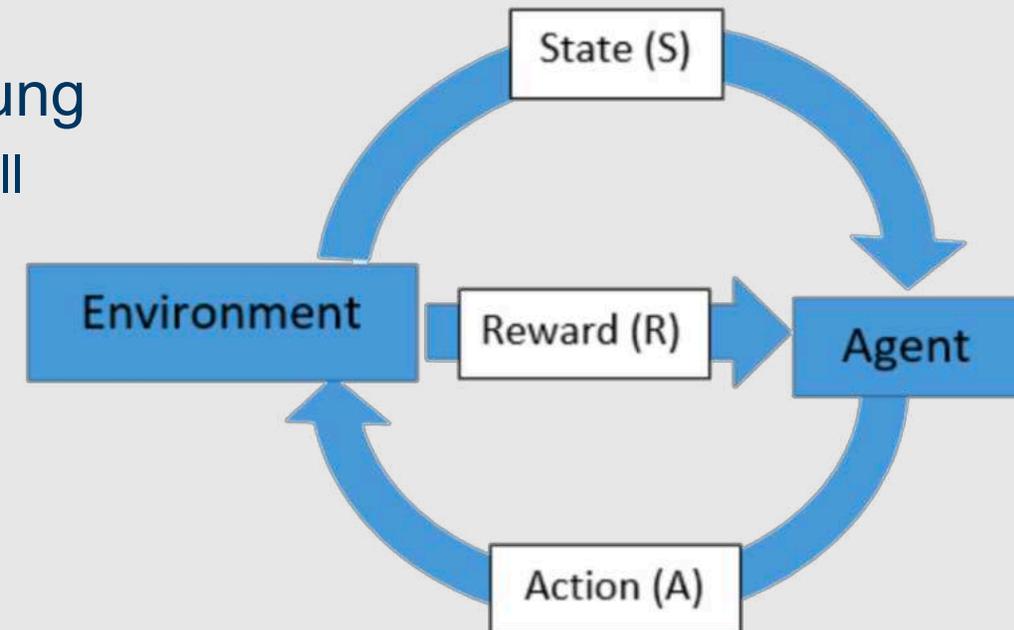
beide Verfahren erfordern manuelle Arbeit

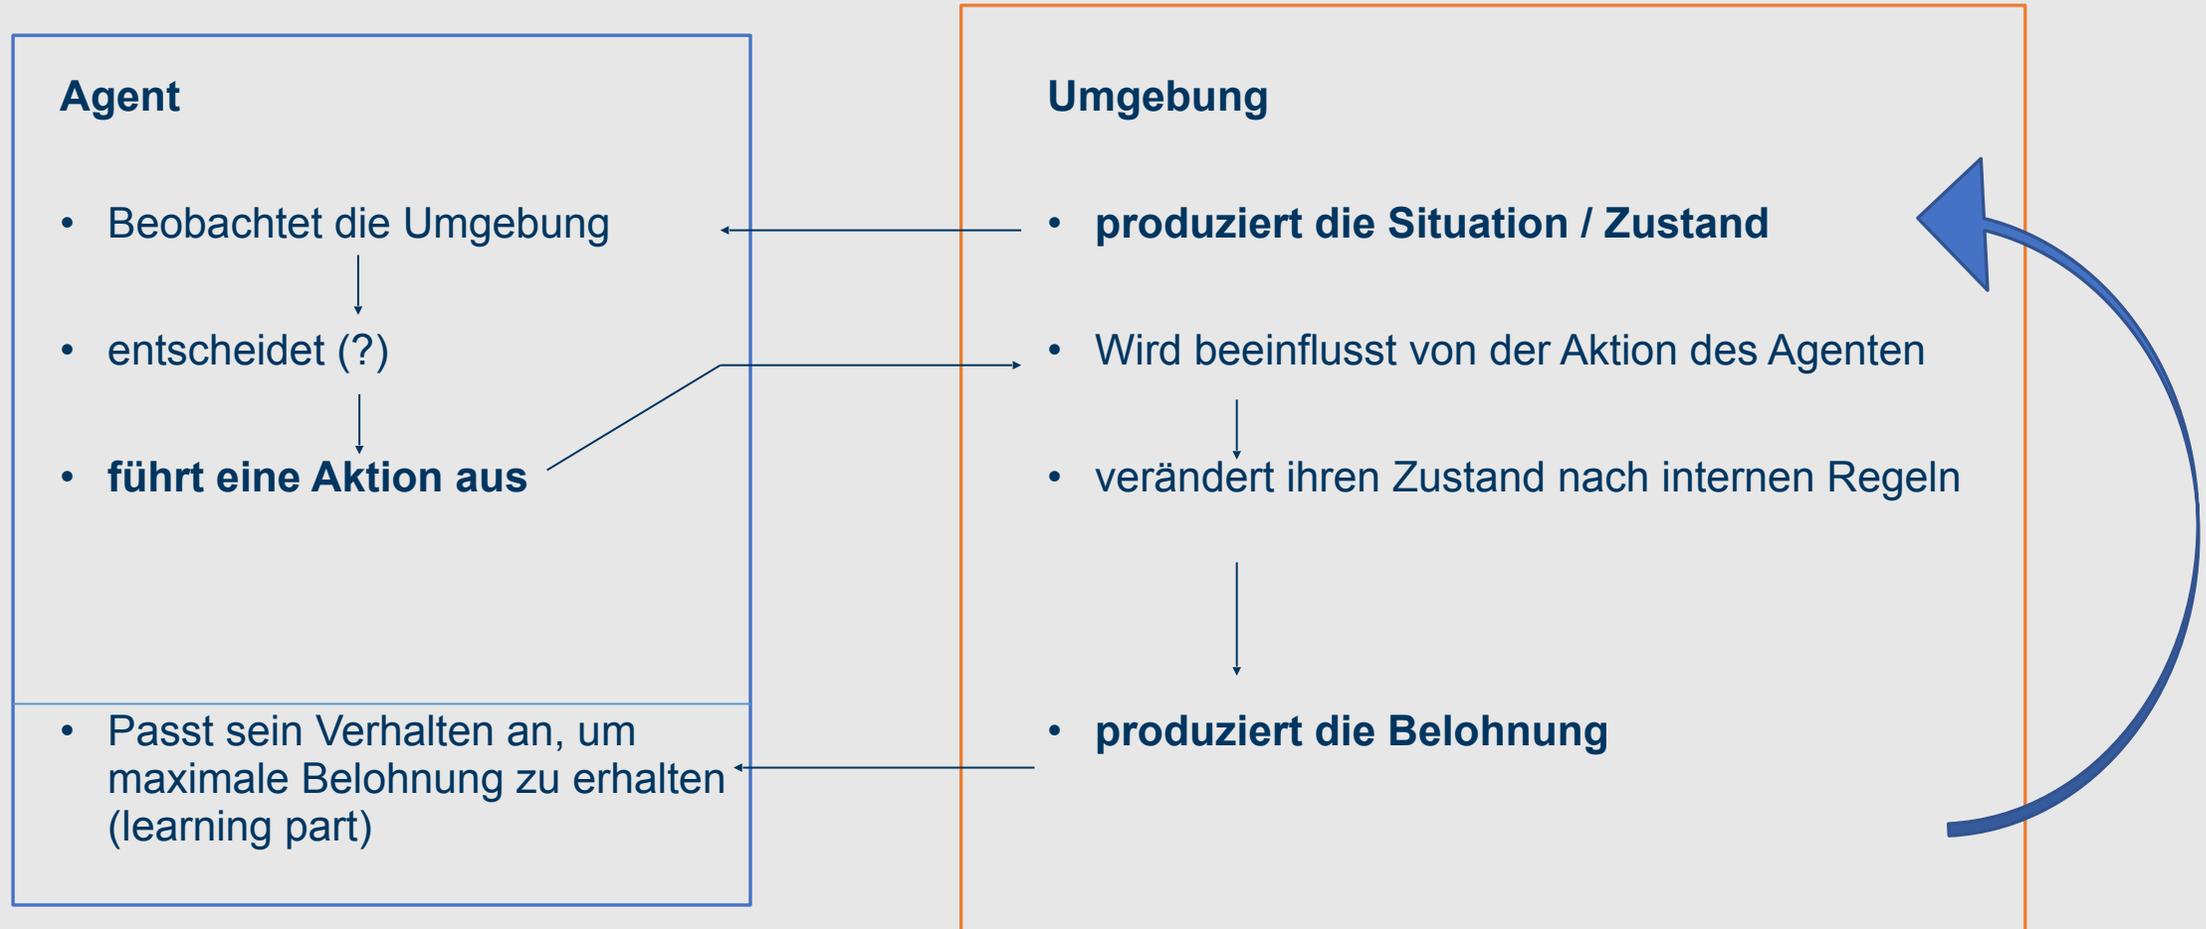
- *Unsupervised Learning*
 - erfordert Interpretation der Ausgabe



Reinforcement Learning

- am Lernverhalten des Menschen orientiert
- Lernen erfolgt durch Interaktion in einer Umgebung
 - dem Agent ist unbekannt welche Aktion er ausführen soll
 - Lernen durch „trial and error“
 - Neues ausprobieren und Bekanntes verbessern
- Ziel ist es die Gesamtbelohnung zu maximieren
 - Bei Auswahl von Aktion müssen zukünftige Konsequenzen in Betracht gezogen werden





■ Supervised Learning

- lernt von gelabelten Trainingsdaten
- kann maximal so gut sein wie die Trainingsdaten
- Wissen ist statisch
- bildet unbekanntes Input in **bekannte** Outputs ab

■ Reinforcement Learning

- lernt eigenständig durch Entscheidungen
- kann übermenschliche Leistungen erbringen

- Wissen ist dynamisch
- bildet Zustände auf Aktionen ab (Strategie)

■ Supervised Learning

- lernt von gelabelten Trainingsdaten
- kann maximal so gut sein wie die Trainingsdaten
- Wissen ist statisch
- bildet unbekanntes Input in **bekannte** Outputs ab

■ Unsupervised Learning

- versucht in einer Datenmenge unbekannte Strukturen zu finden
- Ausgabe muss interpretiert werden

■ Reinforcement Learning

- lernt eigenständig durch Entscheidungen
- kann übermenschliche Leistungen erbringen

- Wissen ist dynamisch
- bildet Zustände auf Aktionen ab (Strategie)

- versucht die Belohnung zu maximieren

- Ausgabe wird von der Umgebung konsumiert

■ Supervised Learning

- lernt von gelabelten Trainingsdaten
- kann maximal so gut sein wie die Trainingsdaten
- Wissen ist statisch
- bildet unbekanntes Input in **bekannte** Outputs ab

■ Unsupervised Learning

- versucht in einer Datenmenge unbekannte Strukturen zu finden
- Ausgabe muss interpretiert werden

■ Reinforcement Learning

- lernt eigenständig durch Entscheidungen
- kann **übermenschliche Leistungen** erbringen

- Wissen ist dynamisch
- bildet Zustände auf Aktionen ab (Strategie)

- versucht die Belohnung zu maximieren

- Ausgabe wird von der Umgebung konsumiert

Ausgezeichnete Leistungen

■ Watson

- Supercomputer kombiniert mit künstlicher Intelligenz
- Entwickelt um Antworten auf Fragen (Suchmaschine)
- Kommuniziert in natürlicher Sprache



■ Watson

- Supercomputer kombiniert mit künstlicher Intelligenz
- Entwickelt um Antworten auf Fragen (Suchmaschine)
- Kommuniziert in natürlicher Sprache



- Februar 2011: **gewann** gegen zwei Champions

■ Watson

- Supercomputer kombiniert mit künstlicher Intelligenz
- Entwickelt um Antworten auf Fragen (Suchmaschine)
- Kommuniziert in natürlicher Sprache

■ Jeopardy!

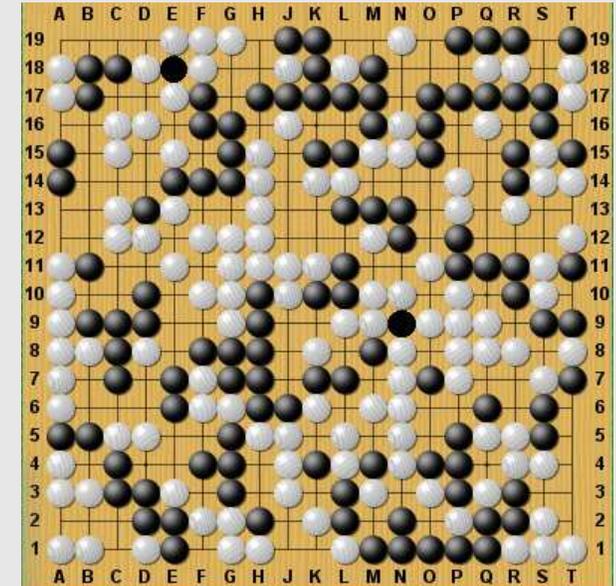
- Ein Fernseh-Quizshow aus den USA
- erfordert Schnelligkeit und Fachwissen

- Februar 2011: **gewann** gegen zwei Champions



■ AlphaGo

- entwickelt von Google's Tochterunternehmen **DeepMind**
- soll ausschließlich **Go** spielen

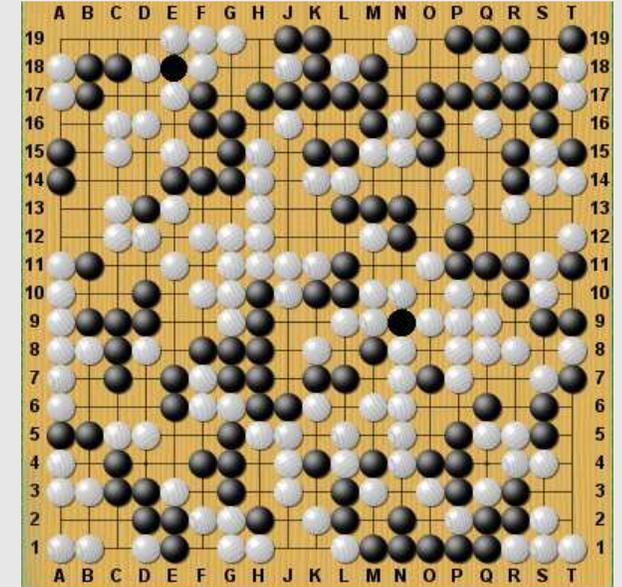


AlphaGo

- entwickelt von Google's Tochterunternehmen **DeepMind**
- soll ausschließlich **Go** spielen

Go

- Ein strategisches Brettspiel
- Bei 19x19 Brettgröße ca. 10^{171} gültige Spielpositionen



■ AlphaGo

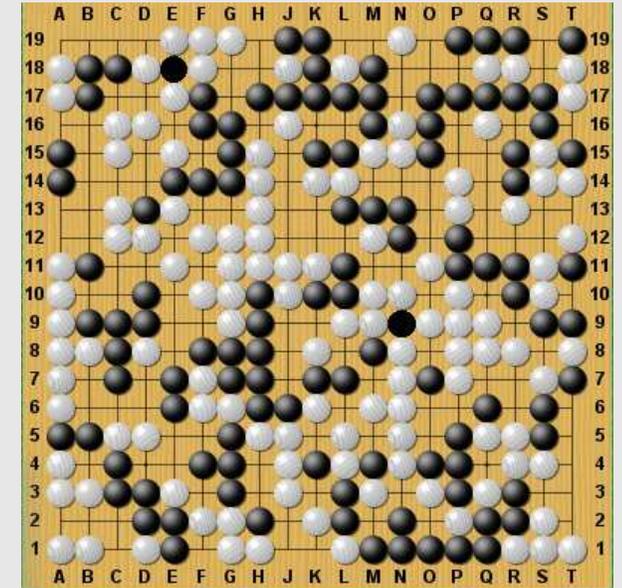
- entwickelt von Google's Tochterunternehmen **DeepMind**
- soll ausschließlich **Go** spielen

■ Go

- Ein strategisches Brettspiel
- Bei 19x19 Brettgröße ca. 10^{171} gültige Spielpositionen

■ Mai 2016: **4:1** gegen einer der besten Spieler (Lee Sedol)

■ Mai 2017: **3:0** gegen Weltranglistenenerste (Ke Jie)



- **AlphaZero** kann **Schach**, **Shogi** und **Go** auf übermenschlichem Niveau spielen
- nach **nur 24 Stunden** trainieren / lernen mit sich selbst
- verwendet die gleichen Hyperparameter für alle Spiele

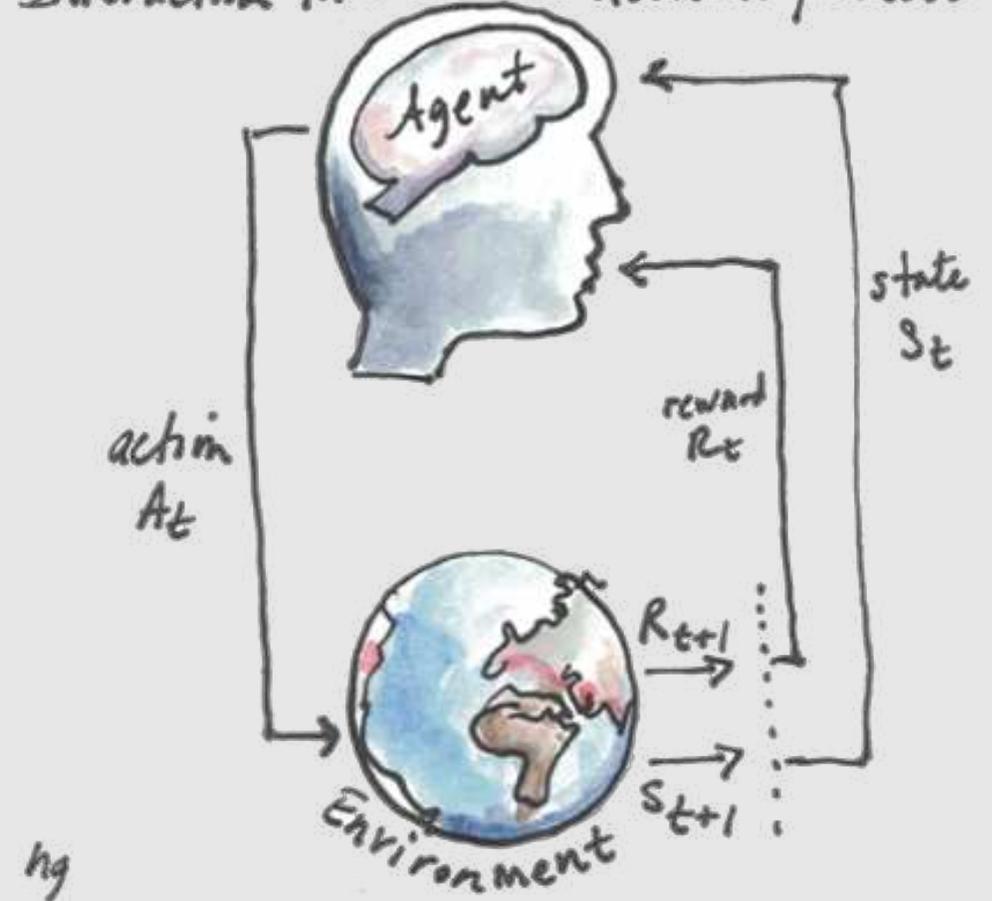
Spiel	Brettgröße Felderanzahl	Zustandsraum-Komplexität (als dekadischer Logarithmus \log_{10})	Spielbaum- Komplexität (\log_{10})
Schach	8×8=64	50 ^[6]	123 ^[6]
Shōgi	9×9=81	71 ^[8]	226 ^[8]
Go	19×19=361	171 ^[10]	360 ^[11]

Markov Decision Process

Basiskomponente

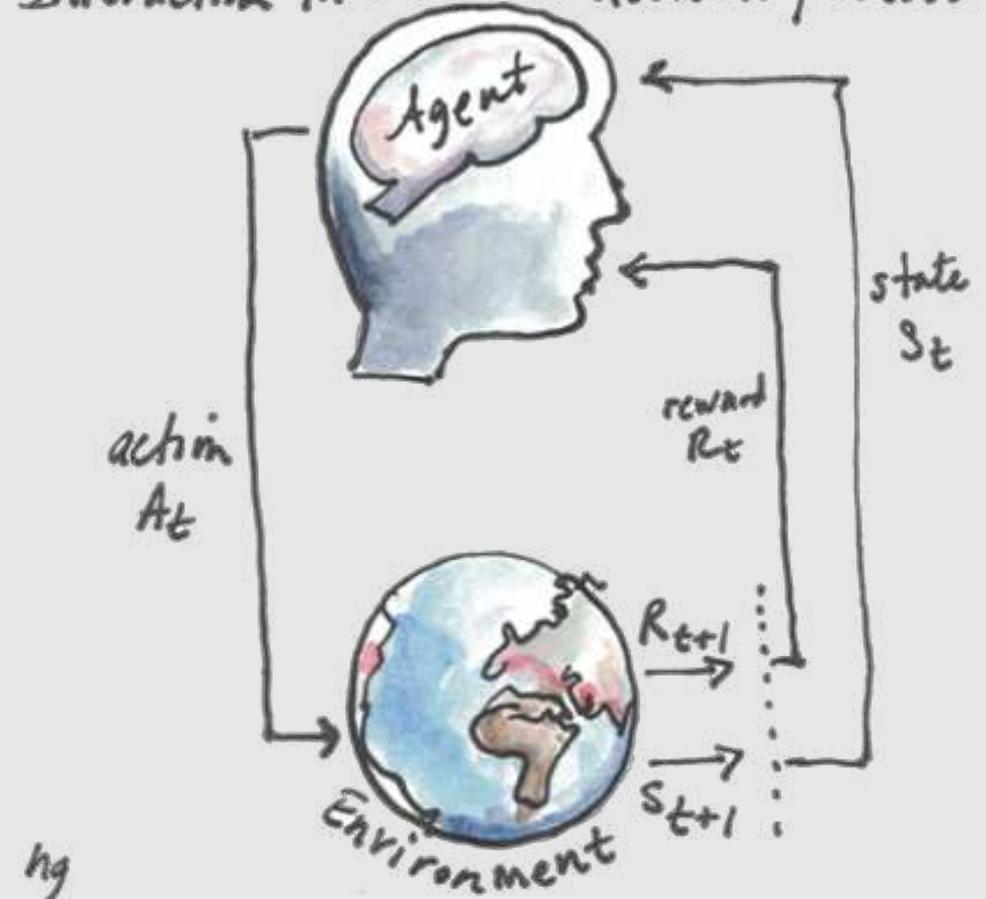
- **Strategie π**
 - Verhalten des Agenten
- **Belohnungssignal**
 - Wie gut hat er sich verhalten

Interaktion in a Markov decision process

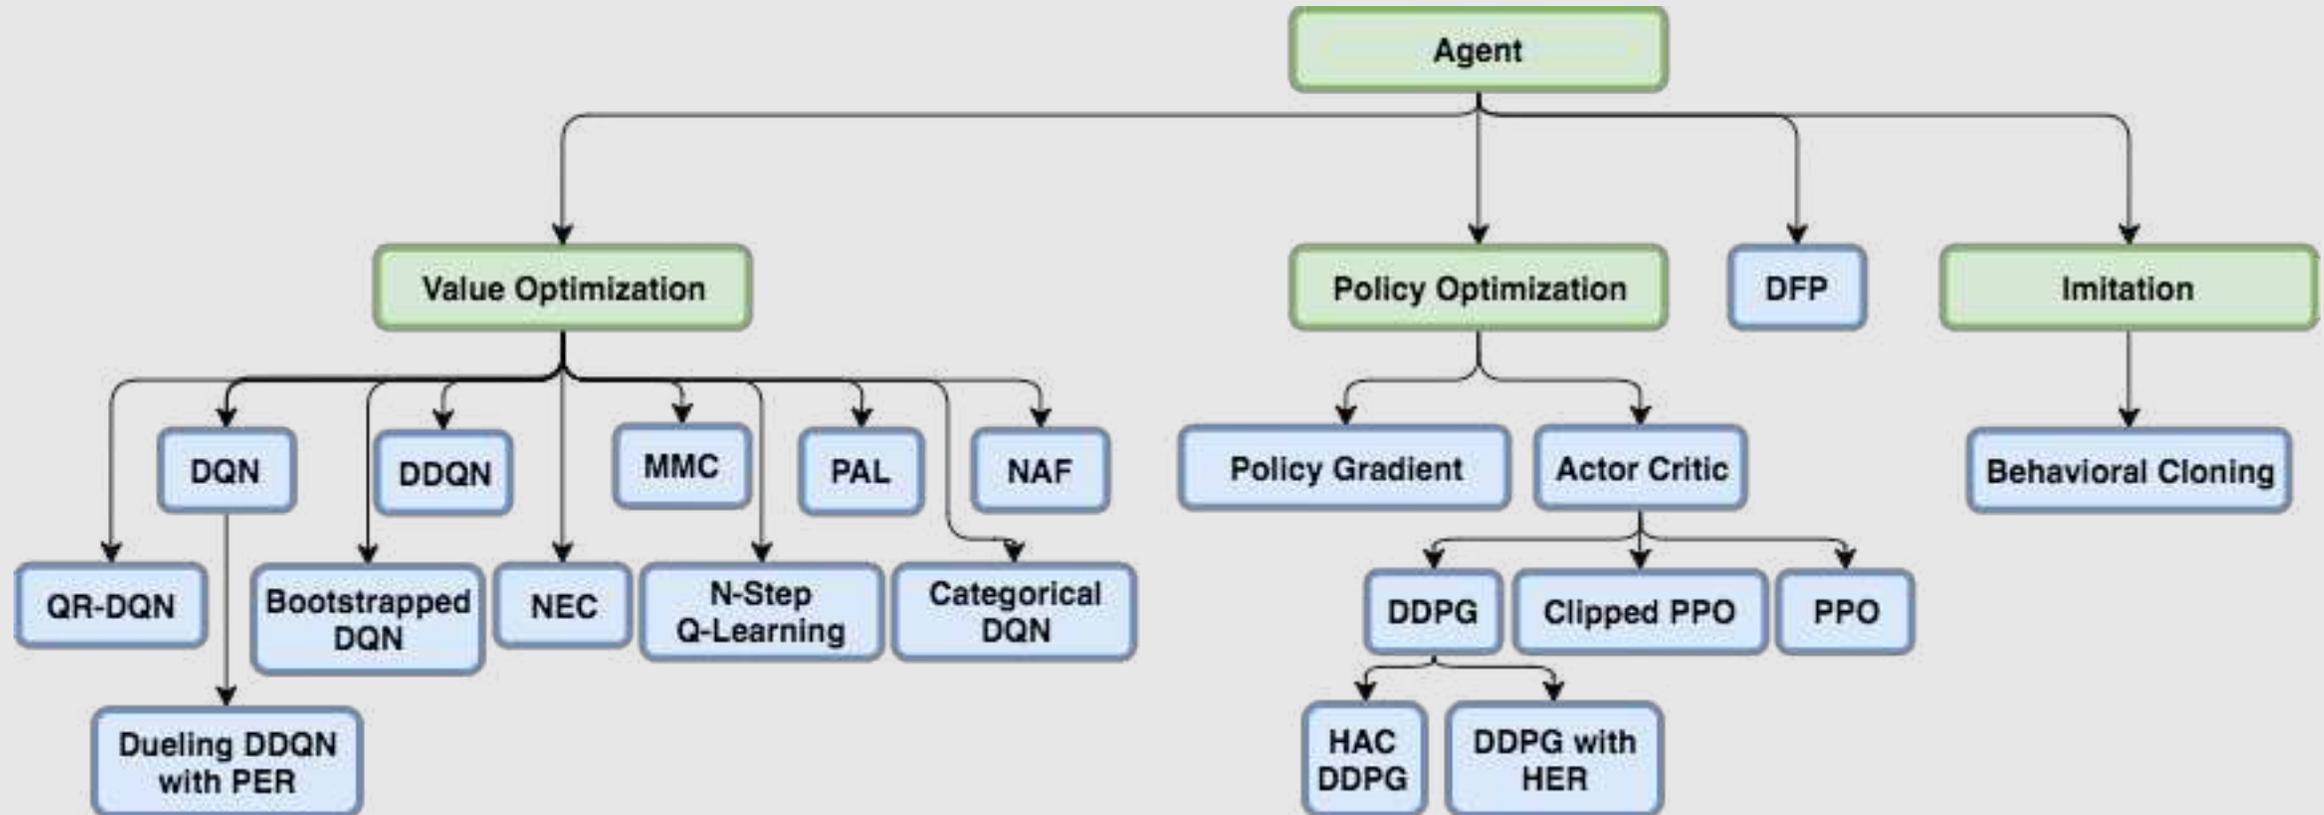


- **Strategie π**
 - Verhalten des Agenten
- **Belohnungssignal**
 - Wie gut hat er sich verhalten
- **Nutzenfunktion**
 - $V(s)$: erwartete Belohnung bei Startzustand s
 - $q(s,a)$: erwartete Belohnung bei Aktion a in s
- **Return G_t**
 - G_t : Gesamtbelohnung zur Zeit t
- **Modell (optional)**
 - \mathcal{P} : Transaktionsmatrix
 - \mathcal{R} : Belohnungsfunktion

Interaktion in a Markov decision process



Lernmethoden

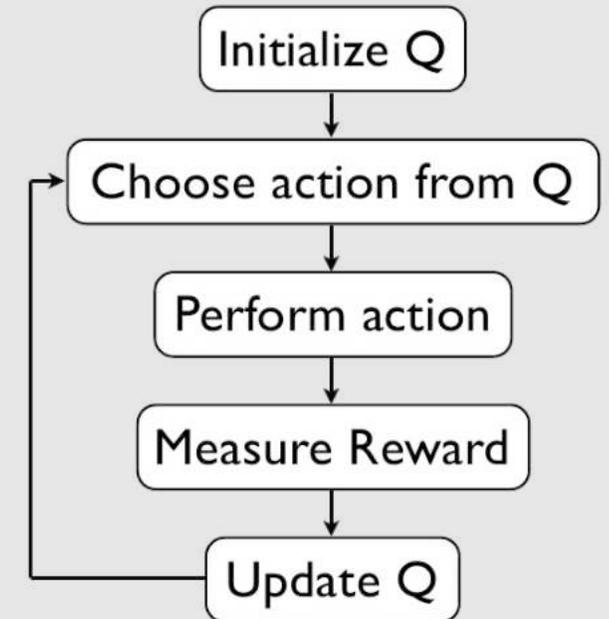


■ Einfaches Lernalgorithmus

- lernt langfristig ein optimales Verhalten
- Ungeeignet für große Zustand-Aktion-Räume

■ Modell frei

- erfordert keine Kenntnisse über die Dynamik der Umgebung

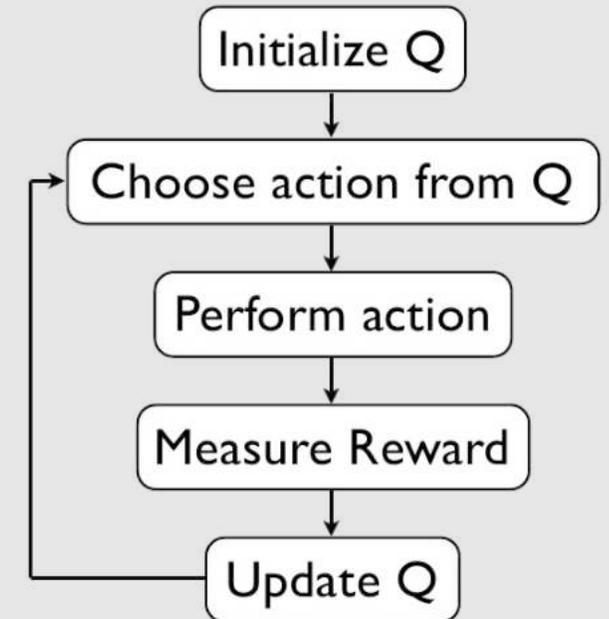


■ Einfaches Lernalgorithmus

- lernt langfristig ein optimales Verhalten
- Ungeeignet für große Zustand-Aktion-Räume

■ Modell frei

- erfordert keine Kenntnisse über die Dynamik der Umgebung



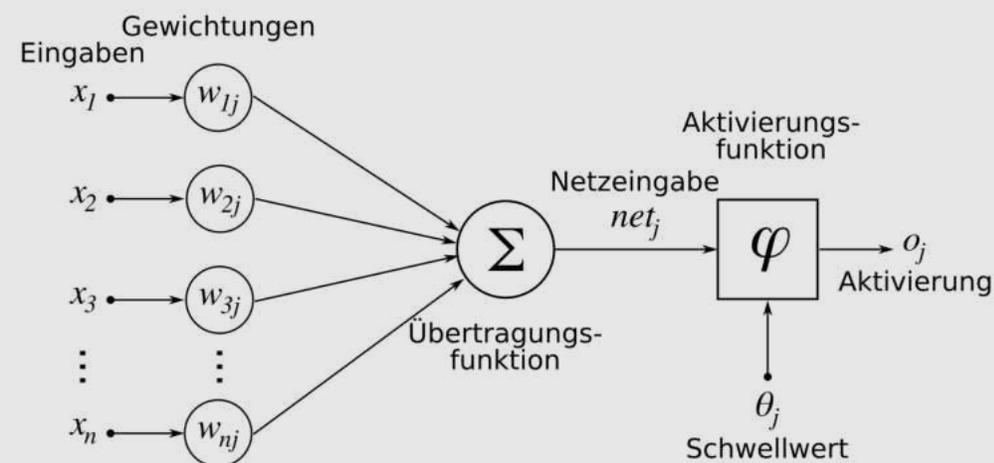
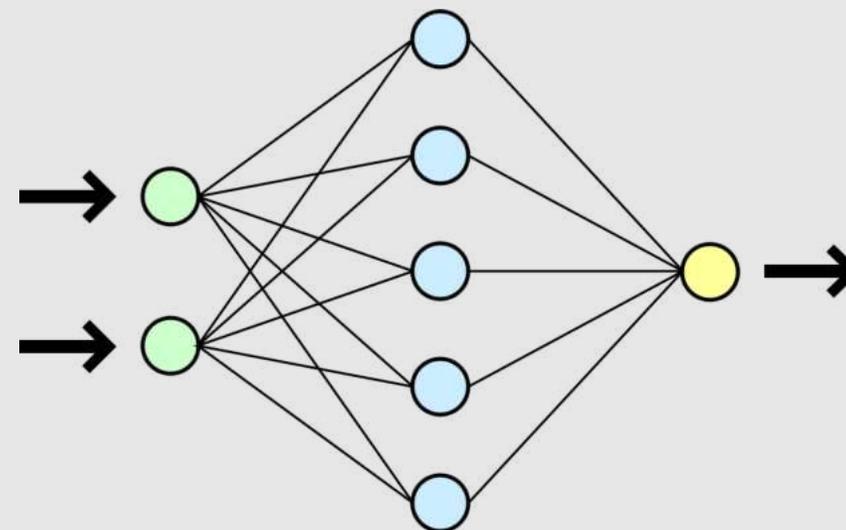
$$Q^{new}(s_t, a_t) \leftarrow (1 - \alpha) \cdot \underbrace{Q(s_t, a_t)}_{\text{old value}} + \underbrace{\alpha}_{\text{learning rate}} \cdot \left(\underbrace{r_t}_{\text{reward}} + \underbrace{\gamma}_{\text{discount factor}} \cdot \underbrace{\max_a Q(s_{t+1}, a)}_{\text{estimate of optimal future value}} \right)$$

learned value

Anwendungen

Hyperparameterwahl bei KNN

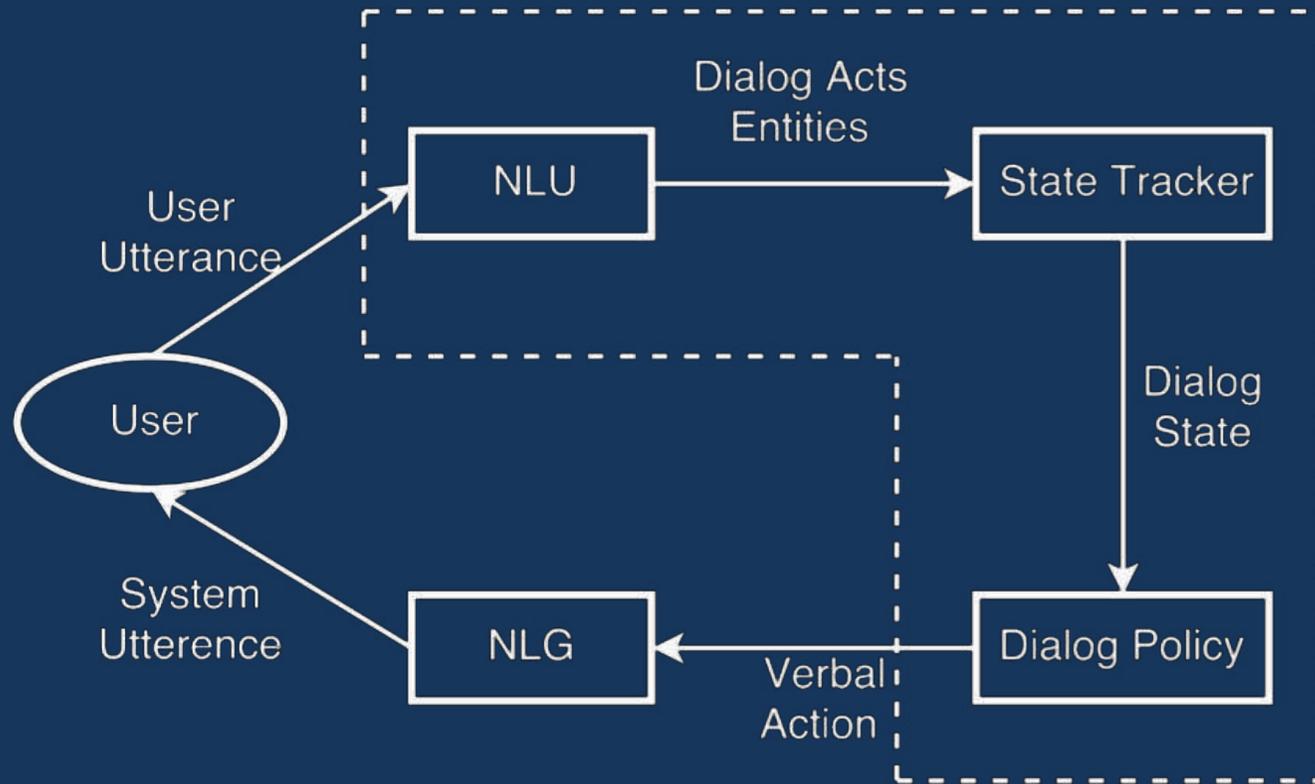
- Anzahl der Hidden-Layer
- Initialwerte der Gewichte
- Aktivierungsfunktionen
- Lernrate
- Anzahl der Epochen



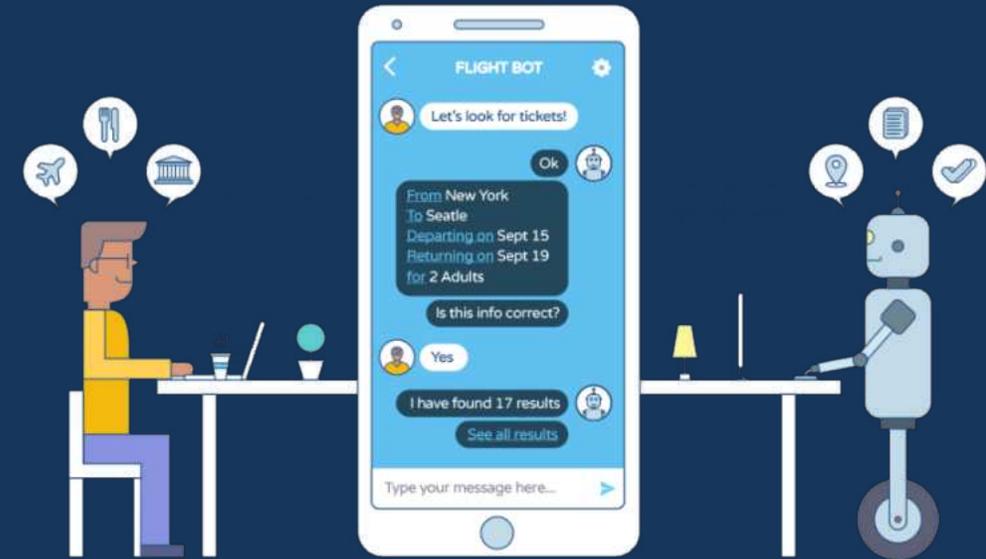
Intelligent Transportation Systems

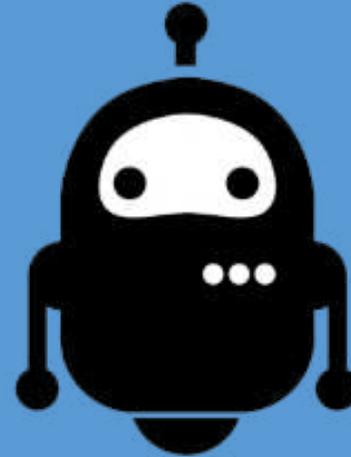


Dialog Systems, chatbots



NLU: natural language understanding
NLG: natural language generation

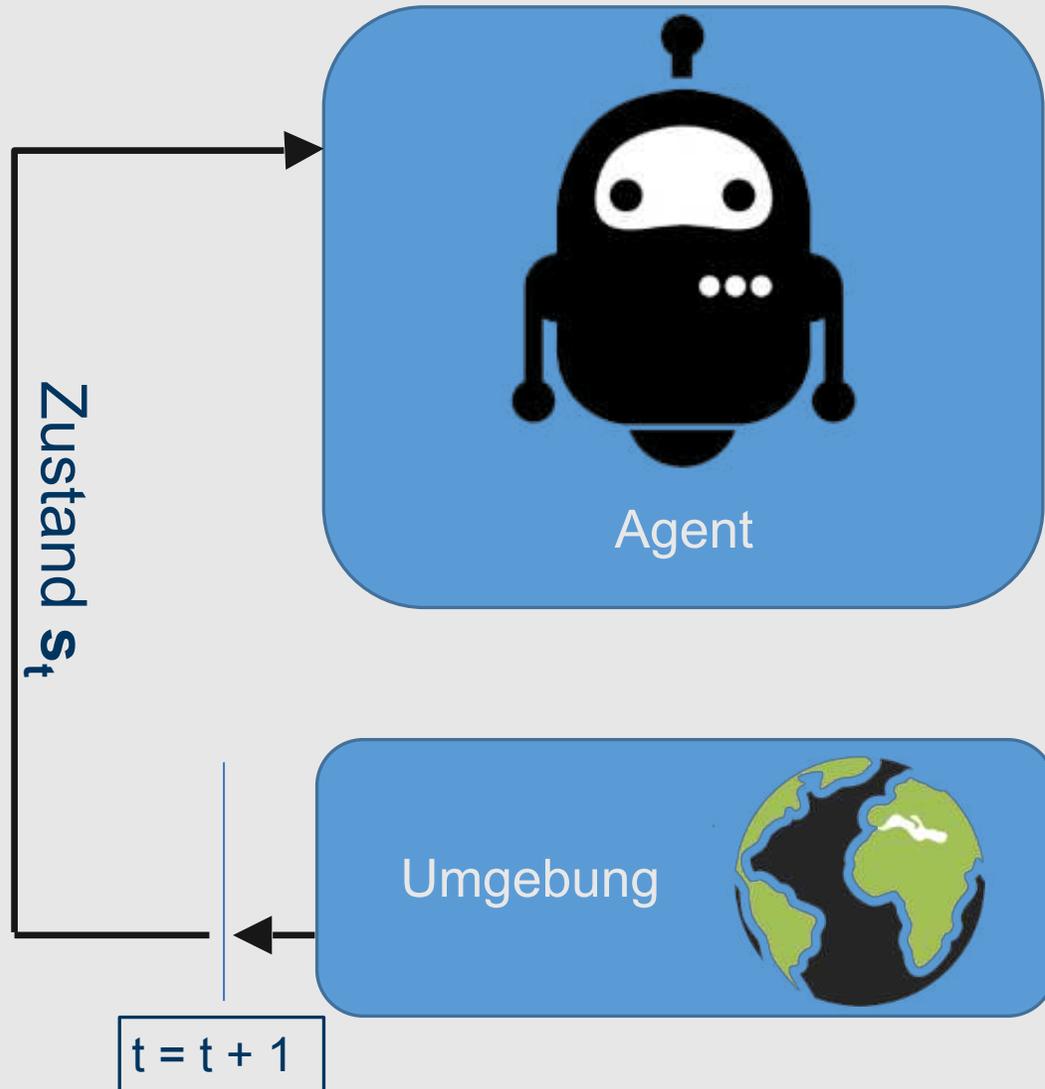




Agent

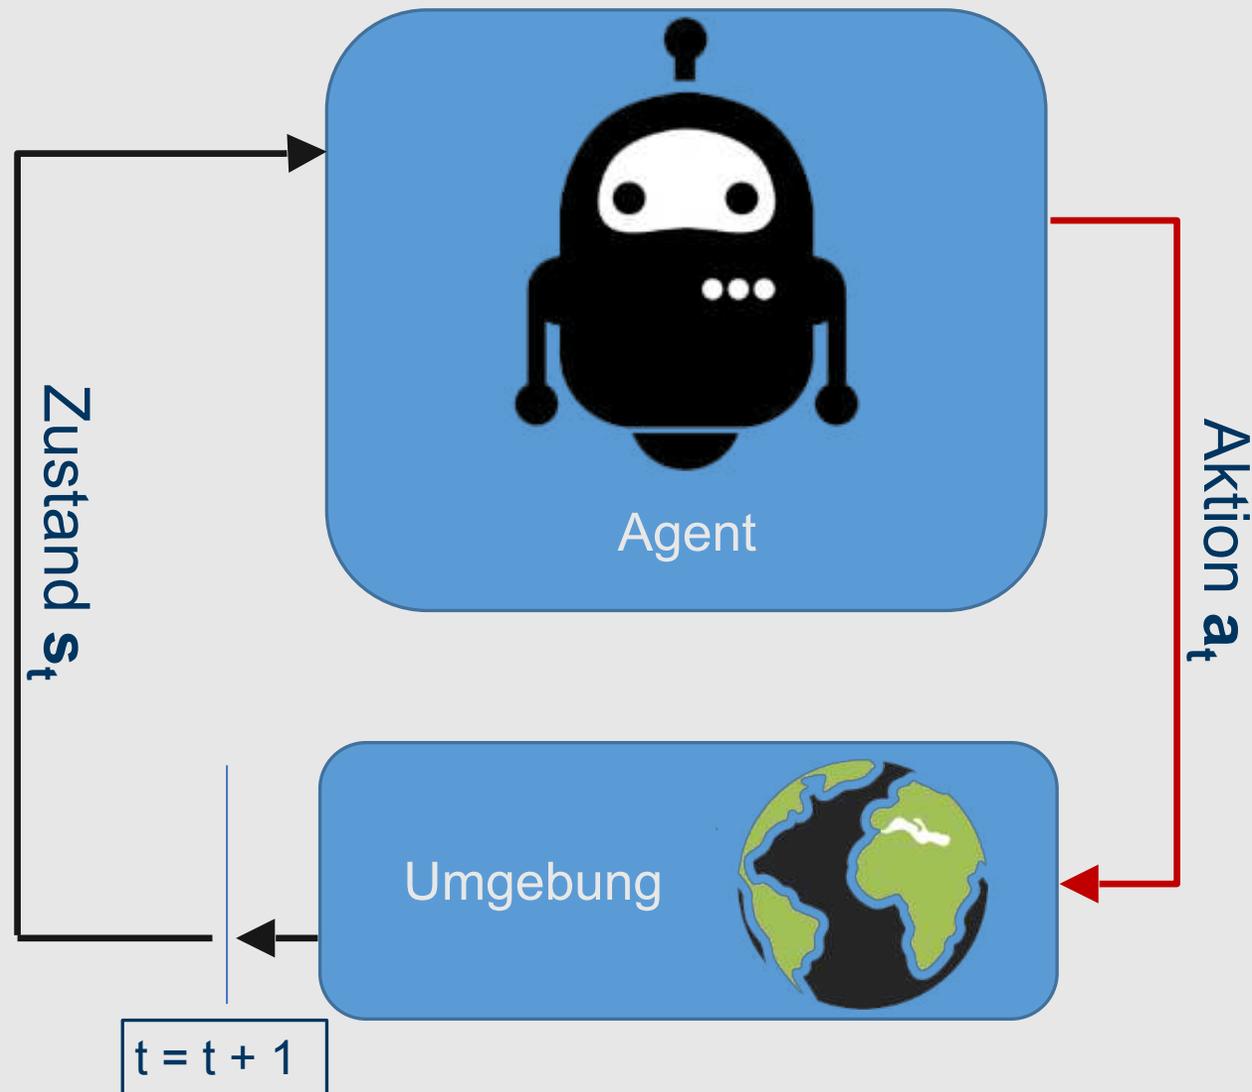
Umgebung



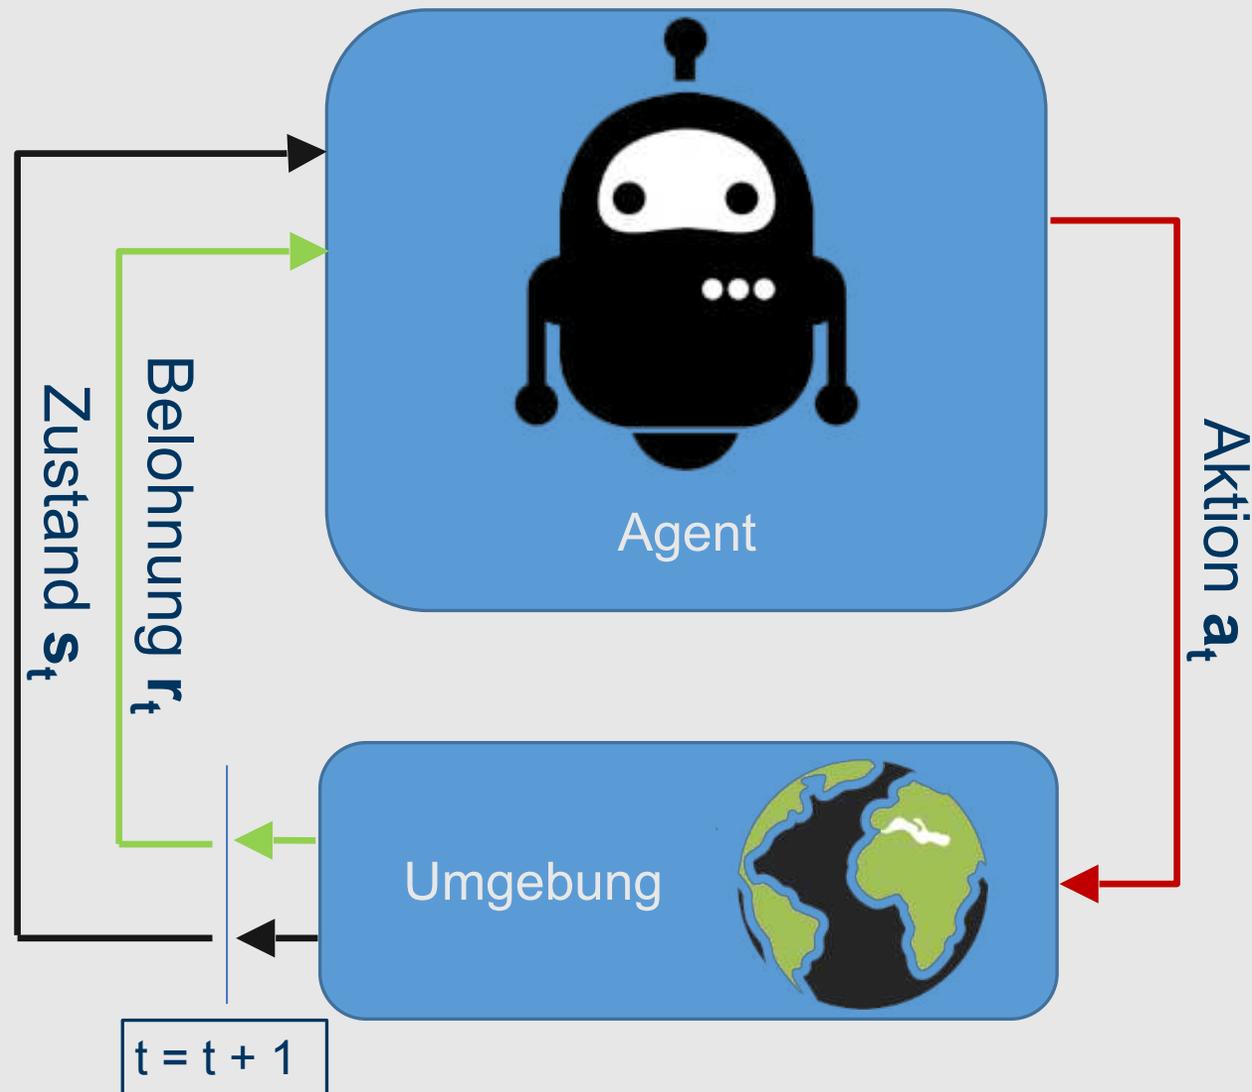


- hat Zustände

Abschluss

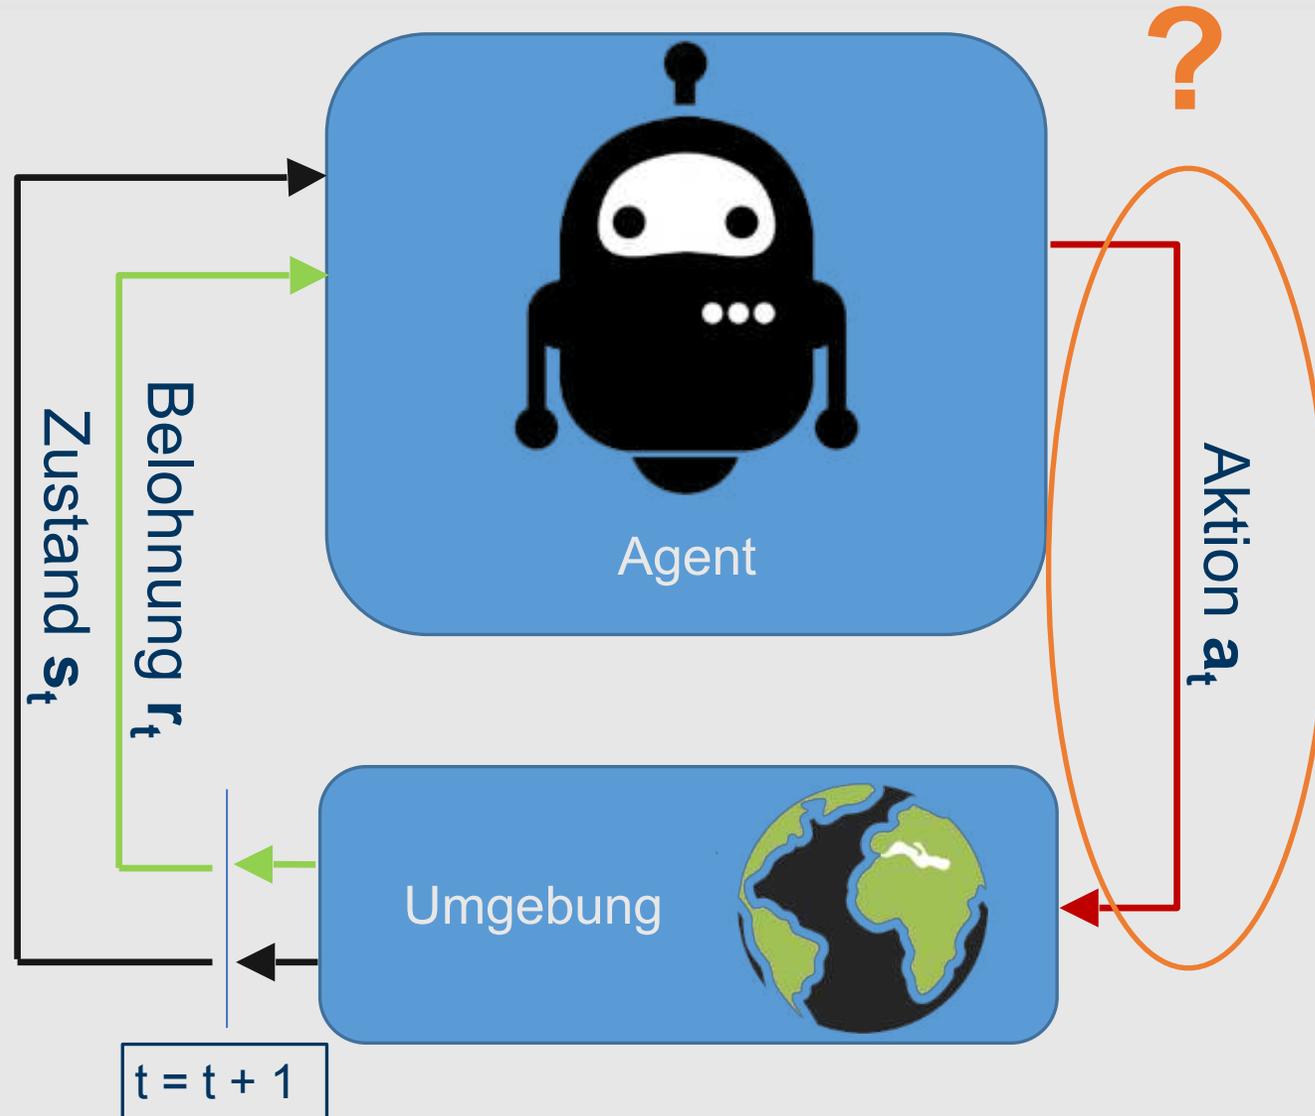


- hat Zustände
- hat Aktionen

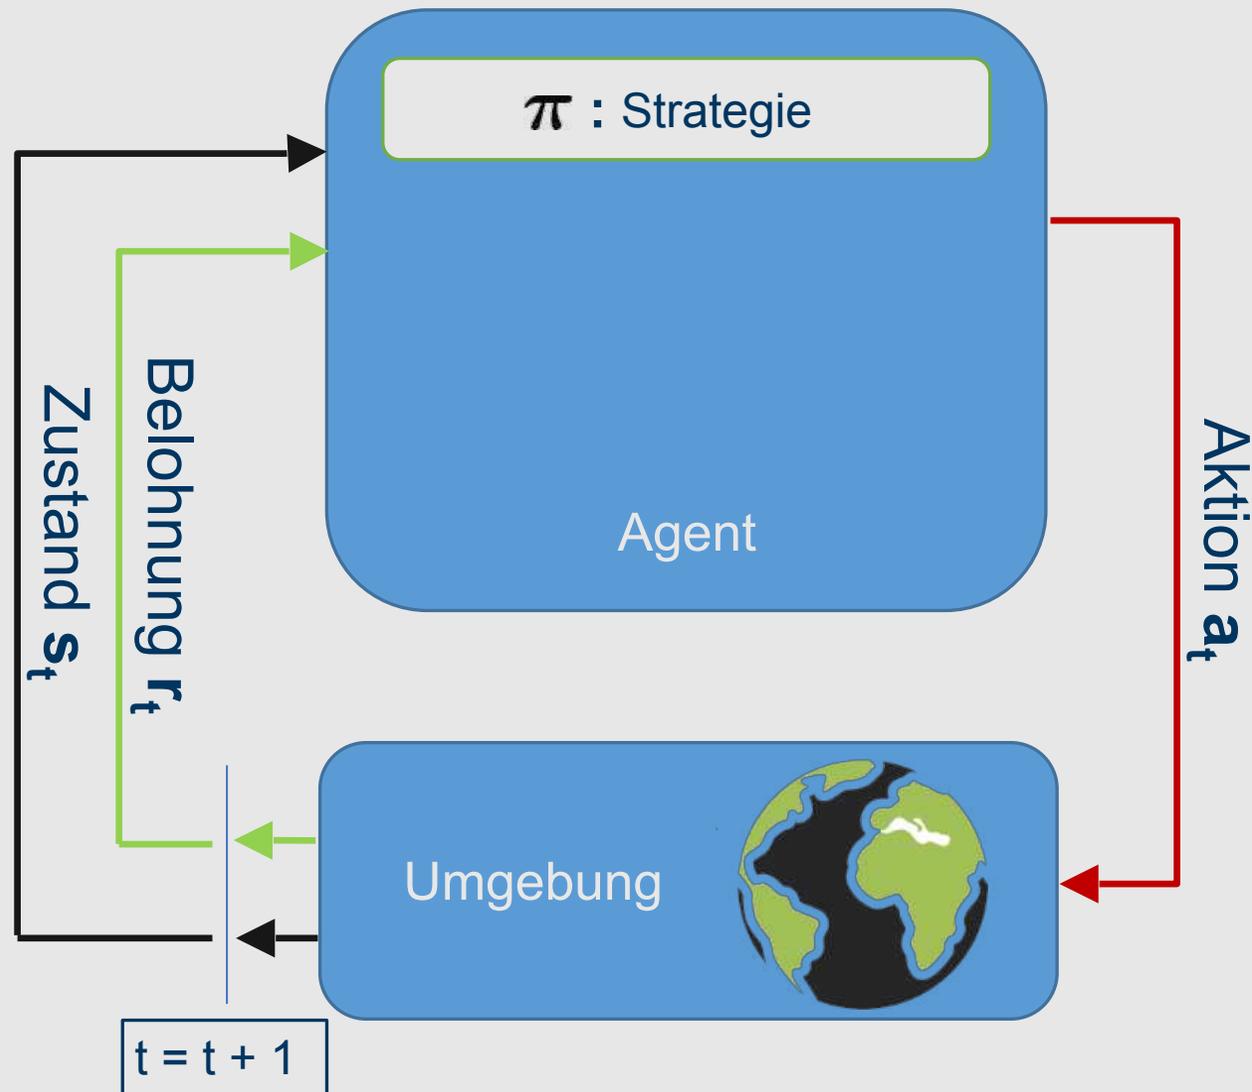


- hat Zustände
- hat Aktionen
- erhält Belohnung von der Umgebung

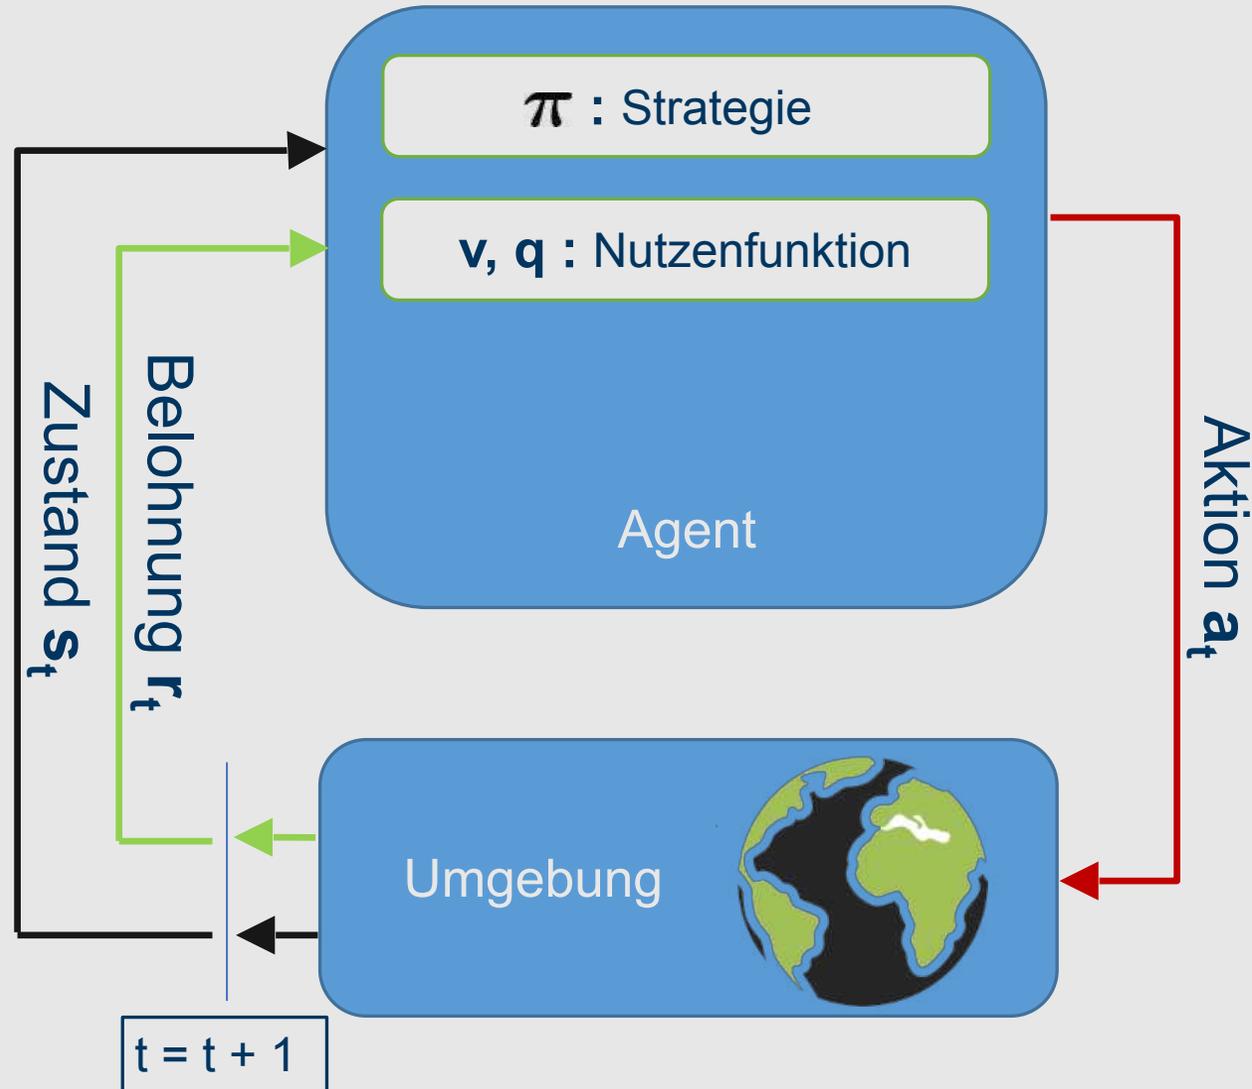
Abschluss



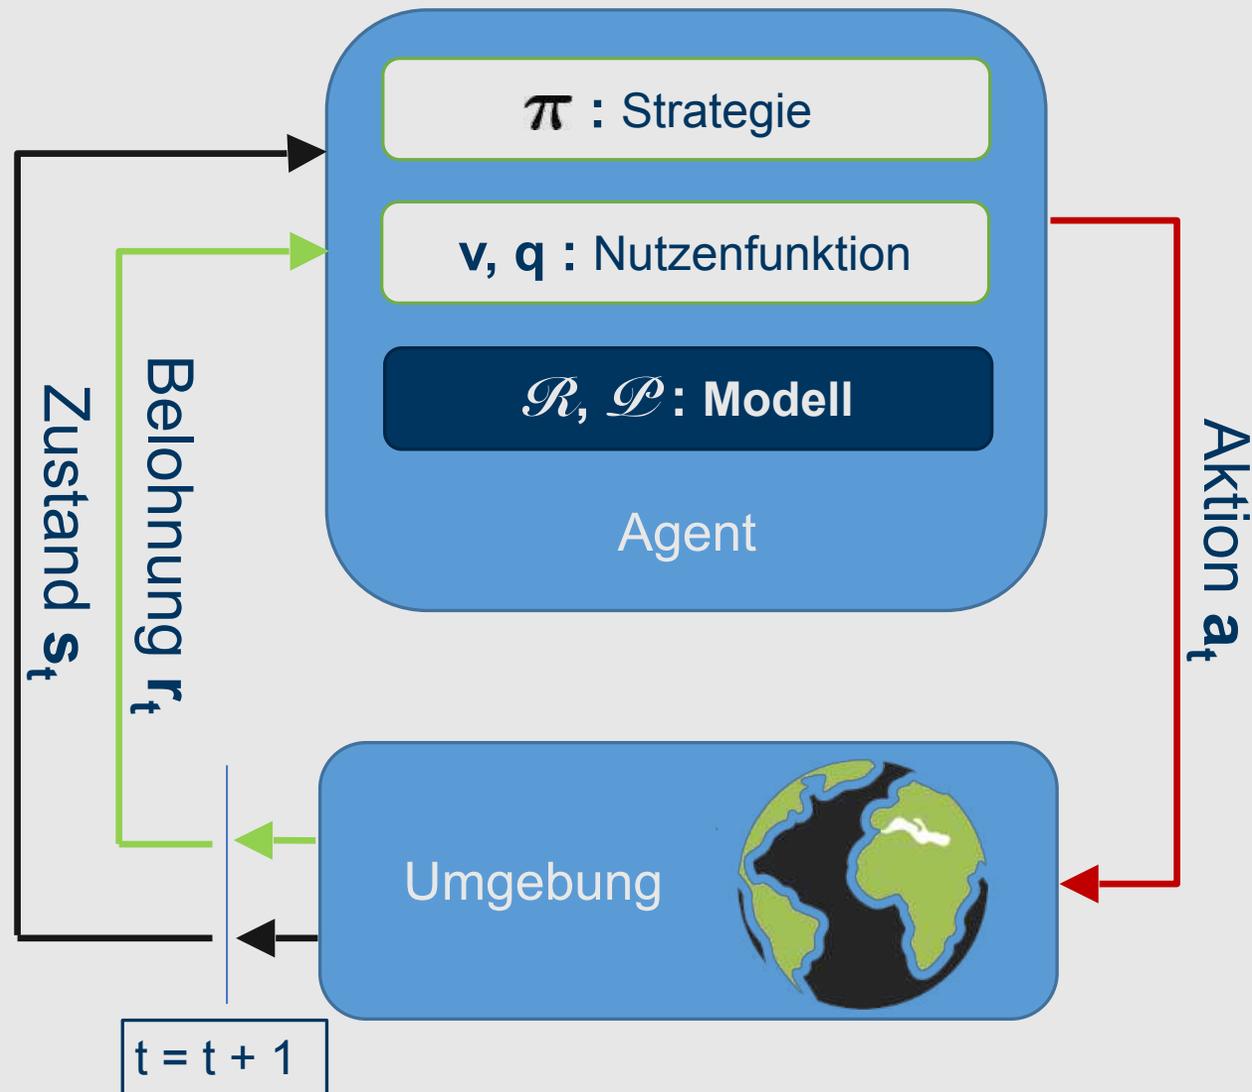
- hat Zustände
- hat Aktionen
- erhält Belohnung von der Umgebung



- hat Zustände
- hat Aktionen
- erhält Belohnung von der Umgebung
- verhält sich nach $\pi(s)$



- hat Zustände
- hat Aktionen
- erhält Belohnung von der Umgebung
- verhält sich nach $\pi(s)$
- $v(s)$: Nutzen von Zustand s
- $q(s, a)$: Nutzen von Aktion a in s



- hat Zustände
- hat Aktionen
- erhält Belohnung von der Umgebung
- verhält sich nach $\pi(s)$
- $v(s)$: Nutzen von Zustand s
- $q(s, a)$: Nutzen von Aktion a in s
- \mathcal{R} : Belohnungsfunktion
- \mathcal{P} : sagt nächsten Zustand s' voraus

Fragen ?