

# Einführung in die Künstliche Intelligenz

## WS14/15 - Prof. Dr. J. Fürnkranz



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

### Beispiellösung für das 7. Übungsblatt (03.02.2015)

#### Aufgabe 1 Reinforcement Learning

- a) Laut Aufgabenstellung erhalten nur (unmittelbare) Aktionen einen Reward (1), die zur Folge haben, dass der Agent sich daraufhin im Feld  $f$  befindet. Diese Aktionen sind im Zustand  $c$  nach unten zu gehen und im Zustand  $e$  sich nach rechts zu bewegen. Alle anderen Aktionen erhalten einen Reward von 0.

$$\begin{array}{cccccc} r(a,r) = 0 & r(b,r) = 0 & r(c,u) = 1 & r(d,o) = 0 & r(e,o) = 0 & \\ r(a,u) = 0 & r(b,u) = 0 & r(c,l) = 0 & r(d,r) = 0 & r(e,r) = 1 & \\ & r(b,l) = 0 & & & r(e,l) = 0 & \end{array}$$

- b) Der akkumulierte erwartete Reward eines Zustandes  $s$  wird folgendermaßen berechnet:  $V^\pi(s) = \sum_{k=0}^{\infty} \gamma^k \cdot r_k$ , wobei die Rewards  $r_k$ , den Rewards entsprechen, die man erhält, wenn man vom Anfangszustand  $s$  aus Aktionen gemäß der Policy  $\pi$  ausführt. Als Beispiel wird die Berechnung von  $V^\pi(d)$  dargestellt: Laut Policy bewegt sich der Agent ausgehend von  $d$  wie folgt:  $\rightarrow a \rightarrow b \rightarrow c \rightarrow f$ , wobei im Feld  $f$  keine Aktion mehr möglich ist.

Die Bewertung  $V^\pi(d)$  ergibt sich also als:

$$\begin{aligned} V^\pi(d) &= \gamma^0 \cdot r(d,o) + \gamma^1 \cdot r(a,r) + \gamma^2 \cdot r(b,r) + \gamma^3 \cdot r(c,u) \\ &= 1 \cdot 0 + 0.8 \cdot 0 + 0.8^2 \cdot 0 + 0.8^3 \cdot 1 \\ &= 0.512 \end{aligned}$$

Analog berechnet man die Bewertungen der restlichen Felder:

$V^\pi(a) = 0.64$	$V^\pi(b) = 0.8$	$V^\pi(c) = 1$
$V^\pi(d) = 0.512$	$V^\pi(e) = 0.64$	

- c) POLICYIMPROVEMENT ändert die aktuelle Policy  $\pi$  für einen Zustand  $s$  um, indem sie die Aktion  $a$  selektiert, die folgendes maximiert:

$$\max_a r(s,a) + \gamma \cdot V^\pi(s') \quad \text{wobei } s' = \delta(s,a)$$

Die aktuelle Policy  $\pi(e)$  für den Zustand  $e$  würde einen Schritt nach **oben** vorgeben, mit der Gesamt-Bewertung 0.64. Für die anderen Aktionen ergibt sich:

**links:**  $r(e,l) + \gamma \cdot V^\pi(d) = 0 + 0.8 \cdot 0.512 = 0.4096$

**rechts:**  $r(e,r) = 1$

Da die Aktion *rechts* im Zustand  $e$  die beste Bewertung hat, würde die aktuelle Policy für den Zustand  $e$  mit der Anweisung  $\pi'(e) = r$  überschrieben werden.

- d) Wir überlegen uns für jedes Feld, welches ein optimaler Weg zu  $f$  wäre. Beispielsweise würde für das Feld  $a$  der Weg  $\rightarrow b \rightarrow c \rightarrow f$  einen optimalen Reward erzielen, genauso wie  $\rightarrow d \rightarrow e \rightarrow f$ , nämlich:

$$= 0.64$$

Analog berechnet man die Bewertungen der restlichen Felder und erhält:

$V^*(a) = 0.64$	$V^*(b) = 0.8$	$V^*(c) = 1$
$V^*(d) = 0.8$	$V^*(e) = 1$	

Die optimale Q-Funktion für alle Zustandspaare lässt sich nun mit den berechneten optimalen Bewertungsfunktionen recht einfach berechnen. Wie aus der Vorlesung bekannt, gilt für die optimale Q-Funktion :

$$Q(s, a) = r(s, a) + \gamma \cdot V^*(s')$$

Im Feld  $a$  erhalten wir beispielsweise :

$$Q(a, r) = r(a, r) + \gamma \cdot V^*(b) = 0 + 0.8 \cdot 0.8 = 0.64$$

$$Q(a, u) = r(a, u) + \gamma \cdot V^*(d) = 0 + 0.8 \cdot 0.8 = 0.64$$

Insgesamt ergibt dies:

$$\begin{array}{lllll} Q(a, r) = 0.64 & Q(b, r) = 0.8 & Q(c, u) = 1 & Q(d, o) = 0.512 & Q(e, o) = 0.64 \\ Q(a, u) = 0.64 & Q(b, u) = 0.8 & Q(c, l) = 0.64 & Q(d, r) = 0.8 & Q(e, r) = 1 \\ & Q(b, l) = 0.512 & & & Q(e, l) = 0.64 \end{array}$$

- e) Die optimale Policy wählt in jedem Feld diejenige Aktion aus, die den höchsten akkumulierten erwarteten Reward verspricht:

$$\begin{aligned} \pi^*(s) &= \operatorname{argmax}_a r(s, a) + \gamma \cdot V^*(s') \\ &= \operatorname{argmax}_a Q(s, a) \end{aligned}$$

Mithilfe der vorigen Teilaufgaben lässt sich einfach die optimale Policy ablesen, indem man für jeden Zustand die Aktion wählt, die den höchsten Q-Wert aufweist. Insgesamt ergibt das folgende graphisch dargestellte Policy:

↓→	↓→	↓
→	→	

- f) Alle Werte  $\hat{Q}(s, a)$  werden zunächst auf null gesetzt. Wir verwenden folgende graphische Ansicht der  $\hat{Q}$ -Werte:

a	$\hat{Q}(a, r) = 0$	$\hat{Q}(b, l) = 0$	b	$\hat{Q}(b, r) = 0$	$\hat{Q}(c, l) = 0$	c
$\hat{Q}(a, u) = 0$			$\hat{Q}(b, u) = 0$			$\hat{Q}(c, u) = 0$
$\hat{Q}(d, o) = 0$			$\hat{Q}(e, o) = 0$			$\hat{Q}(f, o) = 0$
d	$\hat{Q}(d, r) = 0$	$\hat{Q}(e, l) = 0$	e	$\hat{Q}(e, r) = 0$	$\hat{Q}(f, l) = 0$	f

Wir wählen zufällig ein Feld aus, sagen wir  $d$ . Da die beiden Aktionen  $o$  und  $r$  gleich bewertet sind, wählen wir erneut zufällig die Aktion  $r$ .

Nun ergibt sich der neue Wert  $\hat{Q}(d, r) = \hat{Q}(d, r) + \alpha[r(d, r) + \gamma \cdot \max_a \hat{Q}(e, a) - \hat{Q}(d, r)]$ . Da  $\alpha$  auf 1 gesetzt wurde, wird der alte Wert nicht berücksichtigt, d.h. als Update-Regel wird  $\hat{Q}(d, r) = r(d, r) + \gamma \cdot \max_a \hat{Q}(e, a)$  verwendet.

Darüber hinaus sind alle  $\hat{Q}$ -Werte von  $e$  auf 0 gesetzt, so dass  $\hat{Q}(d, r) = 0 + 0.8 \cdot 0 = 0$ .

Im Feld  $e$  wählen wir zufällig die Aktion  $r$  :  $\hat{Q}(e, r) = 1$

Die momentanen  $\hat{Q}$ -Werte sehen dann wie folgt aus:

a	0.0	0.0	b	0.0	0.0	c
0.0			0.0			0.0
0.0			0.0			0.0
d	0.0	0.0	e	1.0	0.0	f

In einer weiteren Iteration starten wir von  $b$  und wählen die Aktion  $u$ . Es ergibt sich nun  $\hat{Q}(b, u) = r(b, u) + \gamma \cdot \max_a \hat{Q}(e, a)$ . Laut unserer aktuellen Q-Funktion ist im Feld  $e$  die optimale Aktion mit 1.0 bewertet, deshalb erhalten wir  $\hat{Q}(b, u) = 0 + 0.8 \cdot 1 = 0.8$ . Im Feld  $e$  wird daraufhin die Aktion  $r$  gewählt und die Q-Werte ändern sich nicht.

a	0.0	0.0	b	0.0	0.0	c
0.0			0.8			0.0
0.0			0.0			0.0
d	0.0	0.0	e	1.0	0.0	f

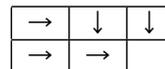
Ein weiterer Durchlauf sei folgenden Weg gegangen :  $d \rightarrow e \rightarrow f$  (wobei die Wahl der nächsten Aktion im Feld  $e$  eindeutig war).

a	0.0	0.0	b	0.0	0.0	c
0.0			0.8			0.0
0.0			0.0			0.0
d	0.8	0.0	e	1.0	0.0	f

Weitere Durchläufe ergaben folgende Wege :  $c \rightarrow f$  und  $a \rightarrow b \rightarrow e \rightarrow f$

a	0.64	0.0	b	0.0	0.0	c
0.0			0.8			1.0
0.0			0.0			0.0
d	0.8	0.0	e	1.0	0.0	f

In weiteren Durchläufen finden keine weiteren Änderungen an den Q-Werten mehr statt. Insgesamt wurde eine (pseudo-)optimale Policy gefunden, die unten zu sehen ist. Beachten Sie, dass die ermittelten Q-Werte nicht immer optimal sein müssen. Die Konvergenz von Q-LEARNING an die optimale Q-Funktion gilt im Allgemeinen nur, wenn jedes Zustands-Aktions Paar beliebig oft besucht wird.



Ein Beispiel für Simulationssequenzen, so dass Q-LEARNING mit einer minimalen Anzahl an Updates konvergiert:  $c \rightarrow f, e \rightarrow f, b \rightarrow c \rightarrow f, d \rightarrow e \rightarrow f, a \rightarrow b \rightarrow c \rightarrow f$

- g) Analog zur Q-Funktion für nicht-deterministische Übergänge muss nun die Bewertungsfunktion  $V^\pi(s)$  modifiziert werden. Das heißt, nun müssen die Wahrscheinlichkeiten für die Übergänge mit Betrachtet werden.  $V^\pi(s_t) = r(s_t, a_t) + \gamma V^\pi(\delta(s_t, a_t))$  wird daher zu  $V^\pi(s_t) = r(s_t, a_t) + \gamma \sum_{s'} P(s'|s, a) V^\pi(s')$

Wir haben nun Wahrscheinlichkeiten  $P(s_{t+1}|s_t, a_t) = 0.9$  und  $P(s_{\text{dead}}|s_t, a_t) = 0.1$ . Da in  $s_{\text{dead}}$  keine Aktionen mehr möglich sind können wir von  $V^\pi(s_{\text{dead}}) = 0$  ausgehen. Somit vereinfacht sich in diesem Fall die Formel zu  $V^\pi(s_t) = r(s_t, a_t) + \gamma \cdot 0.9 \cdot V^\pi(\delta(s_t, a_t))$

Es ergibt sich daher:

$V^\pi(a) = 0.52$	$V^\pi(b) = 0.72$	$V^\pi(c) = 1$
$V^\pi(d) = 0.37$	$V^\pi(e) = 0.52$	

- h) Da unser Reward nun vom Folgezustand abhängt, müssen wir mit  $r(s, a, s')$  arbeiten. Somit wird die Bewertungsfunktion zu  $V^\pi(s) = \sum_{s'} P(s'|s, a)(r(s, a, s') + \gamma V^\pi(s'))$