


(Online) Least-Squares Policy Iteration



TECHNISCHE
UNIVERSITÄT
DARMSTADT

Seminar aus Künstlicher Intelligenz

Albert Slawik



Bildquelle: <http://i.huffpost.com/gen/1803076/images/o-AI-facebook.jpg>

- **Einleitung**
- Relevante Arbeiten
- Methode der kleinsten Quadrate
- Least Squares Temporal Difference
- Incremental Least Squares Temporal Difference
- Ergebnisse
- Diskussion

Wird zur Lösung von Reinforcement Learning Problemen genutzt

Bei großen Problemen lassen sich policies nur approximieren

Temporal Difference zwar schnell aber ungenau und “vergesslich”

LSTD löst Value Function explizit

- Einleitung
- **Relevante Arbeiten**
- Methode der kleinsten Quadrate
- Least Squares Temporal Difference
- Incremental Least Squares Temporal Difference
- Ergebnisse
- Diskussion

Relevante Arbeiten

- S. Bradtke, A. Barto – Linear Least-Squares Algorithms for Temporal Difference Learning
- J. A. Boyan – Least-Squares Temporal Difference Learning
- R. S. Sutton et al. – Incremental Least-Squares Temporal Difference Learning
- R. S. Sutton et al. – iLSTD: Eligibility Traces and Convergence Analysis

- Einleitung
- Relevante Arbeiten
- **Methode der kleinsten Quadrate**
- Least Squares Temporal Difference
- Incremental Least Squares Temporal Difference
- Ergebnisse
- Diskussion

Methode der kleinsten Quadrate

Messwerte: y_i

Modellkurve: $f(x_i)$

Modellparameter:

$$\vec{\alpha} = (\alpha_1, \alpha_2, \dots, \alpha_m) \in \mathbb{R}^m$$

Modellkurvenvektor:

$$\vec{f} = (f(x_1, \vec{\alpha}), \dots, f(x_n, \vec{\alpha})) \in \mathbb{R}^n$$

Methode der kleinsten Quadrate

Fehlerquadratsumme:

$$\sum_{i=1}^n (f(x_i, \vec{\alpha}) - y_i)^2 = \|\vec{f} - \vec{y}\|_2^2.$$

Wähle Parameter, sodass:

$$\min_{\vec{\alpha}} \|\vec{f} - \vec{y}\|_2^2.$$




Abbildung 1: Messpunkte mit durch Least Squares bestimmter Modellfunktion

- Einleitung
- Relevante Arbeiten
- Methode der kleinsten Quadrate
- **Least Squares Temporal Difference**
- Incremental Least Squares Temporal Difference
- Ergebnisse
- Diskussion

Least-Squares Temporal Difference

Ansatz gleich zu TD

Approximation der Value Function:

$$V_{\theta}(s) = \phi(s)^T \theta$$

Feature Representation des Zustandraumes:

$$\phi : \mathcal{S} \rightarrow \mathbb{R}^n$$

Parameter der Value Function:

$$\theta \in \mathbb{R}^n$$

Least-Squares Temporal Difference

Parameter Update nach TD:

$$\begin{aligned}\boldsymbol{\theta}_{t+1} &= \boldsymbol{\theta}_t + \alpha_t \mathbf{u}_t(\boldsymbol{\theta}_t), \text{ where} \\ \mathbf{u}_t(\boldsymbol{\theta}) &= \boldsymbol{\phi}(s_t) \delta_t(V_{\boldsymbol{\theta}}).\end{aligned}$$

Dabei ist α_t die Learning Rate

$V_{\boldsymbol{\theta}}$ der geschätzte Wert in Abhängigkeit von $\boldsymbol{\theta}$

und $\mathbf{u}_t(\boldsymbol{\theta})$ das TD Update zum Zeitpunkt t

$\delta_t(V)$ ist der TD Fehler und Definiert als:

$$\delta_t(V) = r_{t+1} + \gamma V(s_{t+1}) - V(s_t)$$

Least-Squares Temporal Difference

LSTD löst explizit nach den Parametern der Value Function

Dazu wird $\mu_t(\theta)$ als Summe der TD Updates definiert

$$\mu_t(\theta) = \sum_{i=1}^t \mathbf{u}_i(\theta)$$

Da das Update einem Gradienten entspricht, reicht es, die Summe für das Minimum Null zu setzen

Least-Squares Temporal Difference

Umformung ergibt:

$$\begin{aligned}\mu_t(\boldsymbol{\theta}) &= \sum_{i=1}^t \phi_t \delta_t(V\boldsymbol{\theta}) \\ &= \sum_{i=1}^t \phi_t \left(r_{t+1} + \gamma \phi_{t+1}^T \boldsymbol{\theta} - \phi_t^T \boldsymbol{\theta} \right) \\ &= \sum_{i=1}^t \left(\phi_t r_{t+1} - \phi_t (\phi_t - \gamma \phi_{t+1})^T \boldsymbol{\theta} \right) \\ &= \left(\underbrace{\sum_{i=1}^t \phi_t r_{t+1}}_{\mathbf{b}_t} - \underbrace{\sum_{i=1}^t \phi_t (\phi_t - \gamma \phi_{t+1})^T}_{\mathbf{A}_t} \boldsymbol{\theta} \right) \\ &= (\mathbf{b}_t - \mathbf{A}_t \boldsymbol{\theta}).\end{aligned}$$

Da $\mu_t(\boldsymbol{\theta}) = 0$, folgt:

$$\boldsymbol{\theta}_{t+1} = \mathbf{A}_t^{-1} \mathbf{b}_t$$

Least-Squares Temporal Difference

```
0   $s \leftarrow s_0, \mathbf{A} \leftarrow \mathbf{0}, \mathbf{b} \leftarrow \mathbf{0}$ 
1  Initialize  $\theta$  arbitrarily
2  repeat
3    Take action according to  $\pi$  and observe  $r, s'$ 
4     $\mathbf{d} \leftarrow \phi(s) - \gamma \phi(s')$ 
5     $\mathbf{b} \leftarrow \mathbf{b} + \phi(s)r$ 
6     $\mathbf{d} \leftarrow (\phi(s) - \gamma \phi(s'))$ 
7     $\mathbf{A} \leftarrow \mathbf{A} + \phi(s)\mathbf{d}^T$ 
8    if (first update)
9       $\tilde{\mathbf{A}} \leftarrow \mathbf{A}^{-1}$ 
10   else
11      $\tilde{\mathbf{A}} \leftarrow \tilde{\mathbf{A}} \left( I - \left( \frac{\phi(s)\mathbf{d}^T}{1 + \mathbf{d}^T \tilde{\mathbf{A}} \phi(s)} \right) \tilde{\mathbf{A}} \right)$ 
12   end if
13    $\theta \leftarrow \tilde{\mathbf{A}}\mathbf{b}$ 
14 end repeat
```

- Einleitung
- Relevante Arbeiten
- Methode der kleinsten Quadrate
- Least Squares Temporal Difference
- **Incremental Least Squares Temporal Difference**
- Ergebnisse
- Diskussion

Ziel: inkrementelles Berechnen von $\mu_t(\theta)$ nachdem eine Transition beobachtet wurde und θ sich geändert hat

Löst nicht direkt nach den Parametern, die Null ergeben

Vergleichbar mit Gradienten Verfahren, die sich in Richtung Minimum bewegen

Dazu werden b_t und A_t inkrementell in Abhängigkeit des beobachteten Rewards berechnet:

$$\mathbf{b}_t = \mathbf{b}_{t-1} + \underbrace{r_t \phi_t}_{\Delta \mathbf{b}_t}$$

$$\mathbf{A}_t = \mathbf{A}_{t-1} + \underbrace{\phi_t (\phi_t - \gamma \phi_{t+1})^T}_{\Delta \mathbf{A}_t}$$

Nun kann man die Summe der TD Updates des aktuellen Zeitschrittes inkrementell berechnen:

$$\mu_t(\theta_t) = \mu_{t-1}(\theta_t) + \Delta \mathbf{b}_t - (\Delta \mathbf{A}_t)\theta_t$$

Wenn nun gilt:

$$\theta_{t+1} = \theta_t + \Delta \theta_t$$

Kann man das TD Updates des nächsten Zeitschritts ebenfalls inkrementell berechnen:

$$\mu_t(\theta_{t+1}) = \mu_t(\theta_t) - \mathbf{A}_t(\Delta \theta_t)$$

Direktes lösen von $\mu_t(\theta_{t+1}) = 0$ immer noch sehr aufwändig

Berechnung von $\Delta\theta_t$ ebenfalls nur in $O(n^2)$ machbar

Lösung: Ergebnisse aus dem letzten Zeitschritt behalten und nur m einzelne Komponenten neu berechnen:

$$\begin{aligned}\theta_{t+1} &= \theta_t + \alpha_t \mu_t(i) \mathbf{e}_i \\ \mu_t(\theta_{t+1}) &= \mu_t(\theta_t) - \alpha_t \mu_t(i) \mathbf{A}_t \mathbf{e}_i.\end{aligned}$$

```
0   $s \leftarrow s_0, \mathbf{A} \leftarrow \mathbf{0}, \boldsymbol{\mu} \leftarrow \mathbf{0}, t \leftarrow 0$ 
1  Initialize  $\boldsymbol{\theta}$  arbitrarily
2  repeat
3    Take action according to  $\pi$  and observe  $r, s'$ 
4     $t \leftarrow t + 1$ 
5     $\Delta \mathbf{b} \leftarrow \boldsymbol{\phi}(s)r$ 
6     $\Delta \mathbf{A} \leftarrow \boldsymbol{\phi}(s)(\boldsymbol{\phi}(s) - \gamma\boldsymbol{\phi}(s'))^T$ 
7     $\mathbf{A} \leftarrow \mathbf{A} + \Delta \mathbf{A}$ 
8     $\boldsymbol{\mu} \leftarrow \boldsymbol{\mu} + \Delta \mathbf{b} - (\Delta \mathbf{A})\boldsymbol{\theta}$ 
9    for  $i$  from 1 to  $m$  do
10      $j \leftarrow \operatorname{argmax}(|\mu_j|)$ 
11      $\theta_j \leftarrow \theta_j + \alpha\mu_j$ 
12      $\boldsymbol{\mu} \leftarrow \boldsymbol{\mu} - \alpha\mu_j\mathbf{A}\mathbf{e}_i$ 
13  end for
14 end repeat
```

- Einleitung
- Relevante Arbeiten
- Methode der kleinsten Quadrate
- Least Squares Temporal Difference
- Incremental Least Squares Temporal Difference
- **Ergebnisse**
- Diskussion

Ergebnisse

TD: $O(n)$, wenn dünnbesetzt $O(k)$

LSTD: $O(n^2)$ wenn Matrix inkrementell invertiert wird, sonst $O(n^3)$

iLSTD: $O(mn + k^2)$





Abbildung 2: Fehlerverhalten bei unterschiedlichen Problemgrößen

Ergebnisse



- Einleitung
- Relevante Arbeiten
- Methode der kleinsten Quadrate
- Least Squares Temporal Difference
- Incremental Least Squares Temporal Difference
- Ergebnisse
- **Diskussion**

Erweiterung von iLSTD auf $iLSTD(\lambda)$

Konvergenzbeweis von iLSTD

Anwendung in komplexen Applikationen wie Soccer Keepaway

Vielen Dank für Ihre Aufmerksamkeit!

Appendix

Boyan Chain:

