



# Semesterprojekt

## Implementierung eines Brettspiels

(inklusive computergesteuerter Spieler)

Wintersemester 16/17

## (Kleine) Einführung zu

# Künstlicher Intelligenz in Brettspielen

Patrick Schäfer

[patrick.schaefer@hu-berlin.de](mailto:patrick.schaefer@hu-berlin.de)

Marc Bux

[buxmarcn@informatik.hu-berlin.de](mailto:buxmarcn@informatik.hu-berlin.de)


# Herangehensweise

---

- Einstieg: Blog-Post zu Brettspiel-KI in Unity  
<https://madewith.unity.com/stories/boardgame-ai>
- hilfreiche Werkzeuge:
  - **Transparenz**: Denkweise der KI wiedergeben, um Probleme zu erkennen
  - **Batch-Modus**: Neue Builds wiederholt (1000 Mal) gegen alte Builds antreten lassen, um Verbesserungen zu messen
- **regelbasierter** Ansatz:
  - Spielsituation analysieren, Regeln durchgehen
  - wende Regel mit höchster Priorität an, deren Vorbedingung erfüllt ist
  - wenn keine Regel greift, auf Standard-KI ausweichen
- **Workflow**: Spiel gegen KI – neue Ideen implementieren – Test im Batchmodus – Änderungen ggf. übernehmen


# Entscheidungsbäume

- Spiele können als **Bäume** modelliert werden:
  - jeder **Knoten** repräsentiert einen **Zustand** des Spiels
  - jede **Kante** repräsentiert einen möglichen **Spielzug**
  - jedes **Blatt** repräsentiert ein mögliches **Spielende** und lässt sich mittels Gütefunktion (Utility) bewerten
- **Strategien** zur Lösungsfindung (Auswahl):
  - Minimax (für 1on1-Nullsummenspiele)
  - Monte-Carlo-Sampling




# Minimax

- Idee: **minimiere** Verlust bei **maximal** guten Zügen des Gegners
- Vorgehensweise:
  - propagiere Bewertungen der Blätter von unten nach oben
  - alterniere zwischen Minimum und Maximum
  - wähle Kind der Wurzel mit höchstem Wert
- wenn  $k$  Spielzüge zur Auswahl stehen, so ergibt sich beim Vorausschauen von  $n$  Spielzügen ein Baum mit Größe  $O(k^n)$ 
  - Alpha-Beta-Pruning (**Optimierung**), Beschränkung des Suchhorizonts (**Heuristik**)



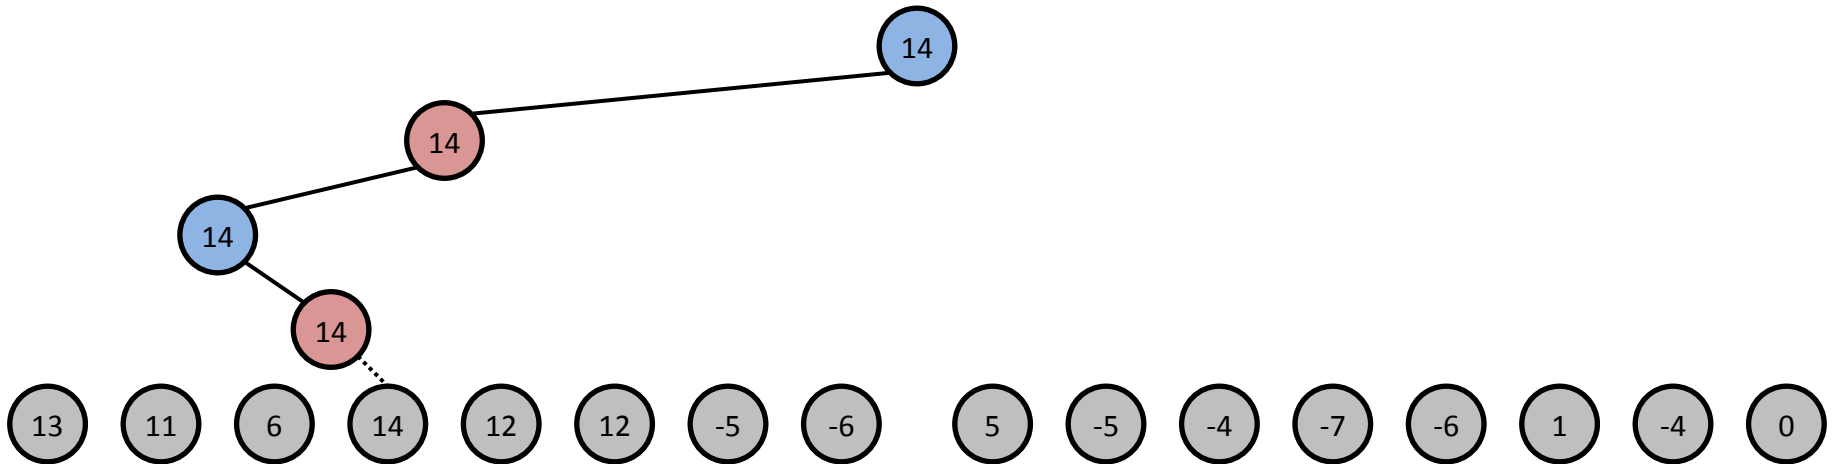
# Alpha-Beta-Pruning

- Idee: Knoten, von denen wir bereits wissen, dass sie suboptimal sind, brauchen nicht weiter betrachtet zu werden
- Vorgehensweise:
  - **Tiefensuche** zu den Blättern, beginnend bei der Wurzel
  - Beim **Backtracking** werden Knoten alternierend mit  $\alpha$ - und  $\beta$ -Werten versehen
  - $\alpha$ -Wert: **maximaler** von Spieler Blau garantierbarer Utility-Wert
  - $\beta$ -Wert **minimaler** von Spieler Rot garantierbarer Utility-Wert
  - Beim **Absteigen** werden  $\alpha$ - und  $\beta$ -Werte nach unten weitergereicht
  - **Verwerfe Äste** ab Knoten, für die gilt  $\alpha \geq \beta$




# Monte-Carlo-Sampling

- Idee: Erweitere Entscheidungsbaum durch **stichprobenartige Simulationen** von Spieldurchläufen mit **zufälligen Zügen**
- **Exploration** vs. **Exploitation** / UCT-Formel: An Knoten  $n$  wähle Nachfolger  $n_i$ , für den  $\frac{w_i}{s_i} + c\sqrt{\ln t/s}$  maximal ist
  - $w_i$ : Anzahl bisher ermittelter Siege bzw. zu erwartender Punktestand ab Knoten  $n_i$
  - $s_i$ : Anzahl bisher durchgeführter Simulationen ab Knoten  $n_i$
  - $c$ : Erkundungs-Parameter (z.B.  $\sqrt{2}$ )
  - $s$ : Anzahl bisher durchgeführter Simulationen ab Knoten  $s$



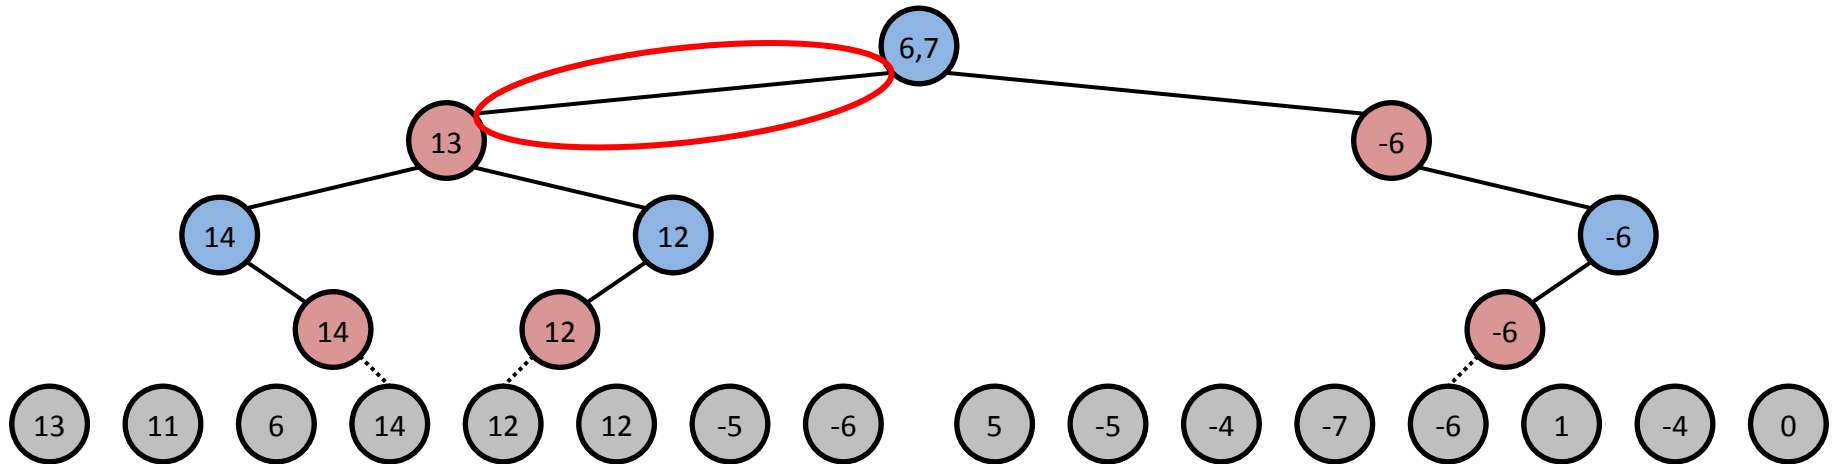
# Monte-Carlo-Sampling

- Idee: Erweitere Entscheidungsbaum durch **stichprobenartige Simulationen** von Spieldurchläufen mit **zufälligen Zügen**
- **Exploration** vs. **Exploitation** / UCT-Formel: An Knoten  $n$  wähle Nachfolger  $n_i$ , für den  $\frac{w_i}{s_i} + c\sqrt{\ln t/s}$  maximal ist
  - $w_i$ : Anzahl bisher ermittelter Siege bzw. zu erwartender Punktestand ab Knoten  $n_i$
  - $s_i$ : Anzahl bisher durchgeführter Simulationen ab Knoten  $n_i$
  - $c$ : Erkundungs-Parameter (z.B.  $\sqrt{2}$ )
  - $s$ : Anzahl bisher durchgeführter Simulationen ab Knoten  $s$



# Monte-Carlo-Sampling

- Idee: Erweitere Entscheidungsbaum durch **stichprobenartige Simulationen** von Spieldurchläufen mit **zufälligen Zügen**
- **Exploration** vs. **Exploitation** / UCT-Formel: An Knoten  $n$  wähle Nachfolger  $n_i$ , für den  $\frac{w_i}{s_i} + c\sqrt{\ln t/s}$  maximal ist
  - $w_i$ : Anzahl bisher ermittelter Siege bzw. zu erwartender Punktestand ab Knoten  $n_i$
  - $s_i$ : Anzahl bisher durchgeführter Simulationen ab Knoten  $n_i$
  - $c$ : Erkundungs-Parameter (z.B.  $\sqrt{2}$ )
  - $s$ : Anzahl bisher durchgeführter Simulationen ab Knoten  $s$





# Weiterführende Links

---

- Vorlesung „General Game Playing“ von Sebastian Wandelt im WS 13/14:  
[https://hu.berlin/vl\\_game](https://hu.berlin/vl_game)
- Ticket to Ride in Java mit implementierter (aber unkommentierter) Minimax- und Monte-Carlo-Baumsuche  
<https://github.com/cooijmanstim/hobo>
- Reddit-Thread mit allerlei nützenswerten Informationen und Erfahrungswerten:  
[https://www.reddit.com/r/gameai/comments/44l6w7/building\\_an\\_ai\\_for\\_a\\_multiplayer\\_turnbased\\_board/](https://www.reddit.com/r/gameai/comments/44l6w7/building_an_ai_for_a_multiplayer_turnbased_board/)

# KI-Challenge: Ablauf

---

- eine User Story, **einwöchige Sprints**, kurze Tech. Refinements
- erste **lauffähige KI zum 16.1.**; wöchentliche Verbesserungen
- wöchentliches **1on1-Turnier** (blau-gelb, blau-rot, gelb-rot)
- zunehmende Punkte für erfolgreiche **Teilnahme** und **Platzierung**
  - 16.1.: 1-1-2, 23.1.: 1-2-3, 30.1.: 2-3-5, 6.2.: 3-5-8, 13.2.: 5-8-13
  - 0 Punkte, wenn KI wiederholt abstürzt oder Spiel nicht terminiert
- optional: zusätzliches Turnier für Einzelabgaben
  - K.O.-System; Beginn im Halbfinale
  - vorzugsweise (aber nicht zwingend) 1on1
- verteiltes Setting mit lokalem Netzwerk:
  - wir stellen Rechner für Spielservers und visualisieren Spiel auf Beamer
  - Turnierteilnehmer verbinden sich mit eigenen Rechnern