

Multi-Agent MCTS



TECHNISCHE
UNIVERSITÄT
DARMSTADT

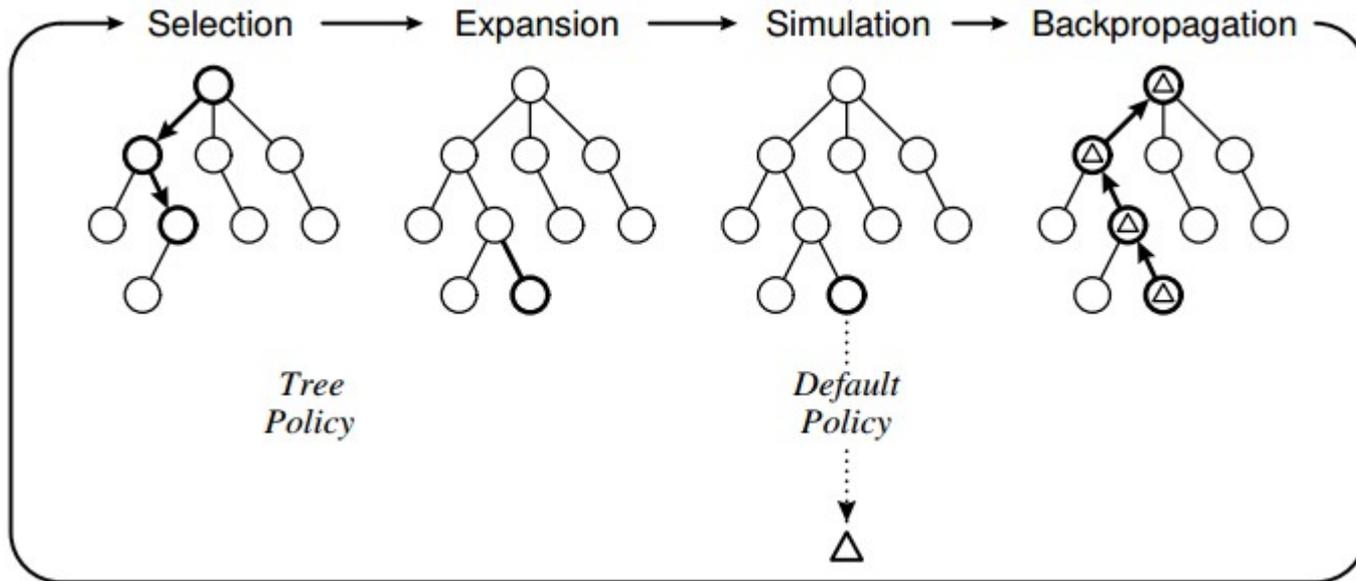
Seminar aus maschinellem Lernen

Tjark Vandommele

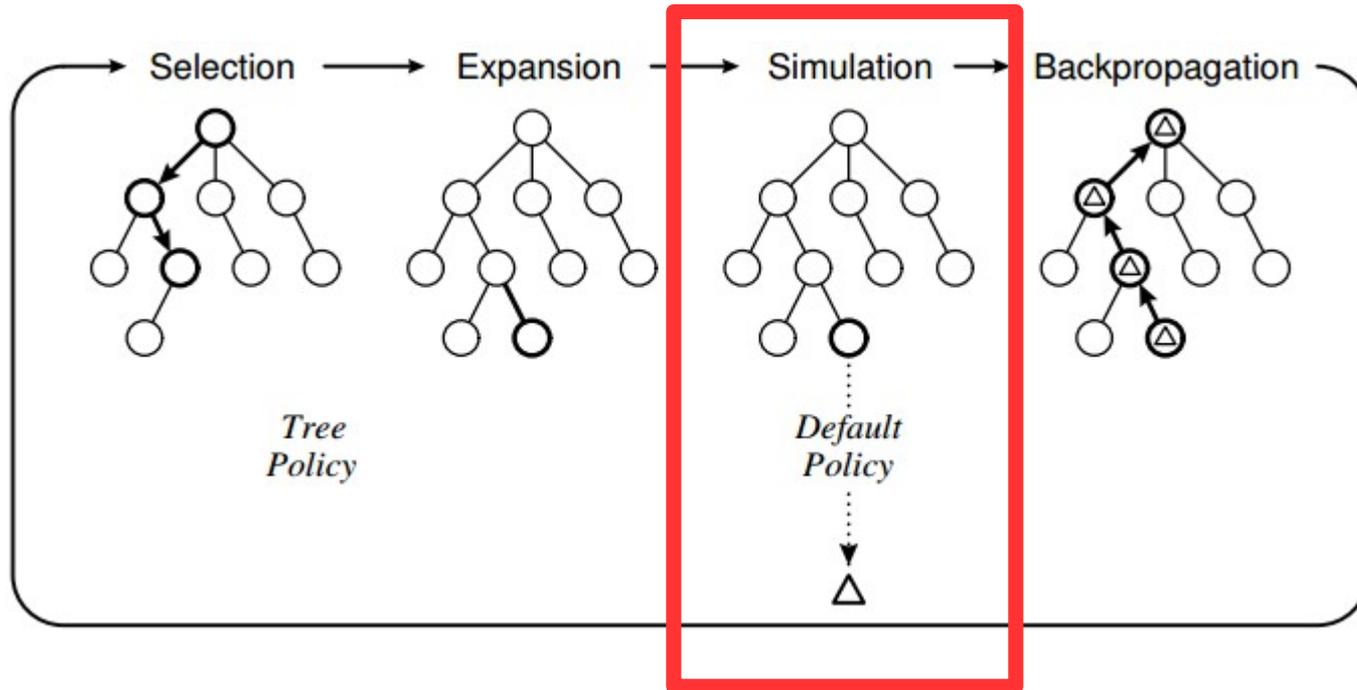
Agenda

- Motivation
- Der Algorithmus
- Implementation
- Performance
- Fazit & Ausblick
- Quellen

Motivation



Motivation

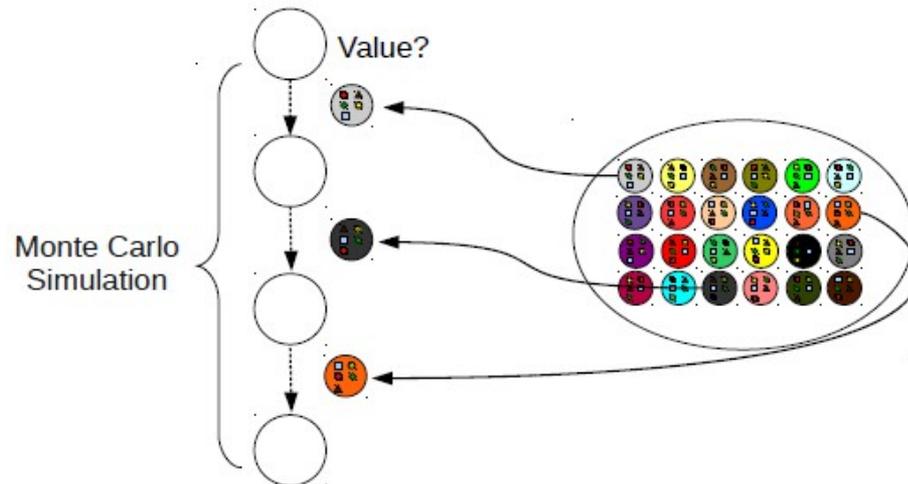


- Random policy führt zu schlechten Zügen
- Eine konkrete Heuristik ist möglicherweise nicht die Beste

→ Verschiedene Heuristiken (Agenten) nutzen

Der Algorithmus

Ursprüngliche Idee: Turnier unterschiedlicher Agenten gegeneinander
→ Hoher Aufwand, kaum Verbesserung

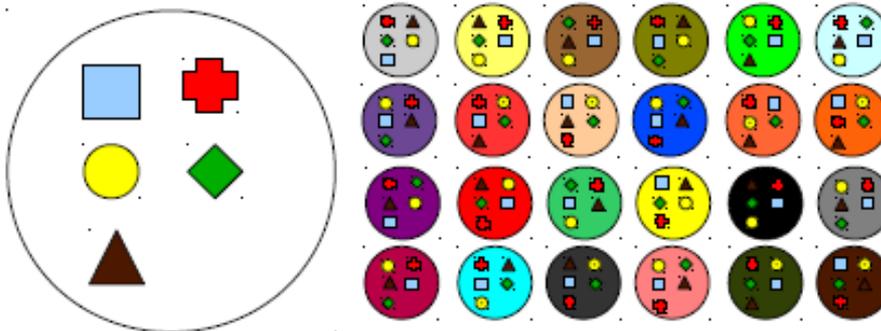


Neue Idee: Für jeden Simulations-Schritt einen anderen Agenten wählen
→ Mehr Exploration
→ Weniger schwache Züge

Implementation

Agenten erzeugen

- Basis ist die hierarchische Heuristik von *Fuego*
 - Nakade
 - Atari Capture
 - Atari Defend
 - Lowlib
 - Pattern
- Neuordnung der 5 Teil-Heuristiken führt zu 120 hierarchischen Heuristiken



$$5! = 120$$

Implementation

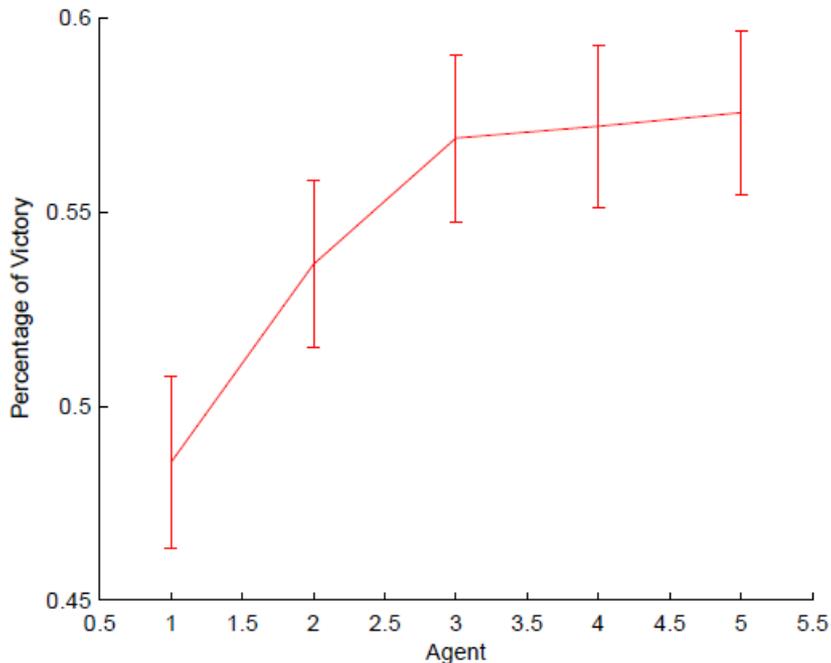
Agenten auswählen



- Erster Versuch mit 120 Agenten vs. Fuego nur 41,2% ($\pm 2,1\%$) Erfolg
→ Scheinbar schlechte Agenten verantwortlich
- Einfacher Lernalgorithmus, um die besten Agenten zu finden
 1. Beginne mit dem original Fuego Agenten
 2. Füge einen zufälligen Agenten hinzu
 3. Überprüfe ob neue Agentenkombination besser ist als bisherige
 4. Wenn ja behalte den neusten Agenten; wenn nicht entferne ihn
 5. Wiederhole bis alle 120 Agenten getestet wurden
- Greedy hill climbing Algorithmus
- Führt nicht zwangsläufig zur optimalen Agentenkombination
- Potential für Verbesserungen

Performance

Reiner Zufall

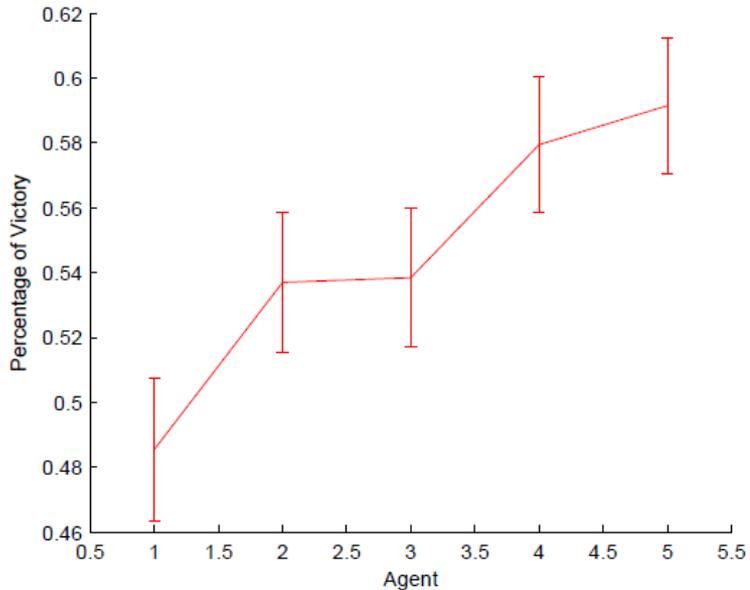


- 5 Agenten gefunden
- 57,55% ($\pm 2,1\%$) Erfolg
- Verbesserung um 9%

- Alle Experimente auf 9x9 Go Brett
- Je 500 Spiele als Weiß und Schwarz
- Gegner immer Standard Fuego
→ Eine Simulation pro Blatt

Agent Number	Percentage of Victory
0	48.50% \pm 2.20%
5 (α)	52.85% \pm 2.15%
6 (β)	53.60% \pm 2.15%
64	57.30% \pm 2.15%
70	29.60% \pm 1.90%

Performance Händisch angepasst



- 15 „gute“ Agenten ausgewählt
- Teils intuitiv, teils via trial and error
- „Gute“ Agenten werden zuerst überprüft

- 5 Agenten gefunden
- 59,15% ($\pm 2,1\%$) Erfolg
- Weitere Verbesserung um 1,6%
- Teils identische Agenten wie zuvor

Agent Number	Percentage of Victory
0	48.55% \pm 2.20%
1 (α)	54.40% \pm 2.15%
2 (β)	54.55% \pm 2.15%
3	57.05% \pm 2.15%
42	50.90% \pm 2.20%

Fazit & Ausblick

Fazit:

- Multi-Agent Ansatz kann Single-Agent Fuego schlagen
- Ein Team aus Agenten kann stärker sein als seine Individuen
- Auch „schlechte“ Agenten können das Team stärker machen
- Erstaunlicherweise sehr kleine Teams aus fünf Agenten

Ausblick:

- Algorithmus um Agenten auszuwählen sollte verbessert werden
- Gruppen von Agenten sollten betrachtet werden
- Andere Heuristiken bzw. Heuristik-Bausteine denkbar
- Performance gegen andere Ansätze muss untersucht werden

Quellen

- L. S. Marcolino and H. Matsubara, **“Multi-Agent Monte Carlo Go”**
 - Proc. Int. Conf. Auton. Agents Multi. Sys., Taipei, Taiwan, 2011, pp. 21–28.
- M. Enzenberger, M. Müller, B. Arneson, and R. B. Segal, **“Fuego - An Open-Source Framework for Board Games and Go Engine Based on Monte Carlo Tree Search”**
 - IEEE Trans. Comp. Intell. AI Games, vol. 2, no. 4, pp. 259–270, 2010.

Fragen

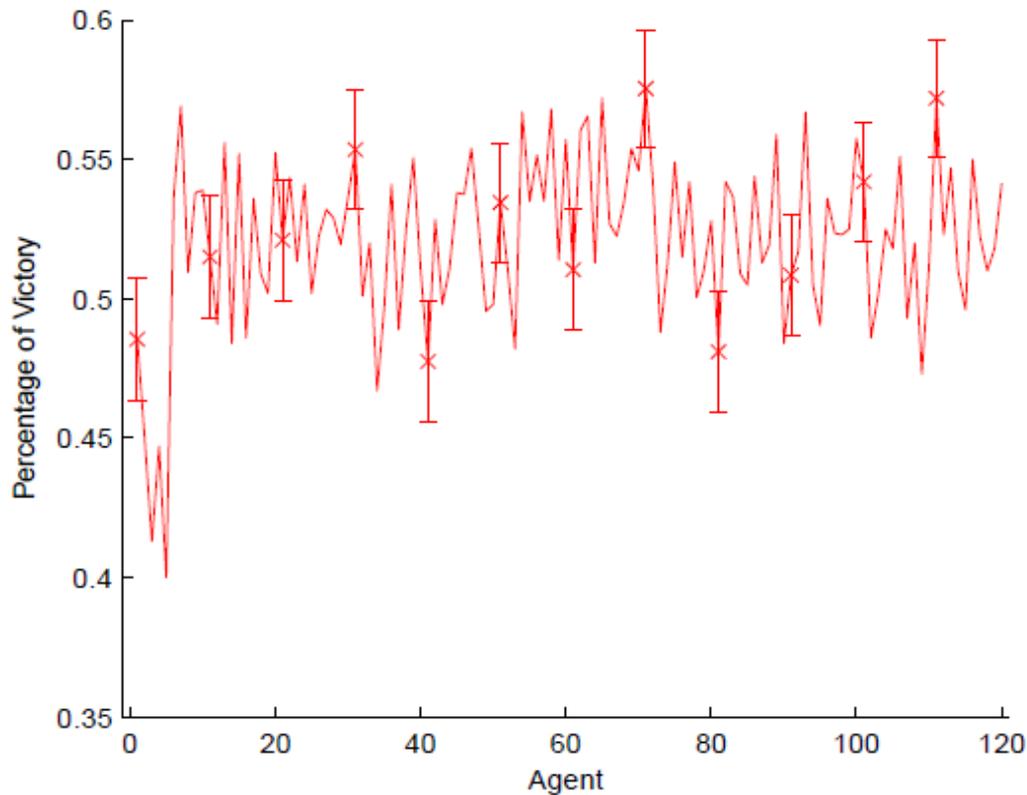


TECHNISCHE
UNIVERSITÄT
DARMSTADT

Danke für die Aufmerksamkeit!
Gibt es noch Fragen?

Backup

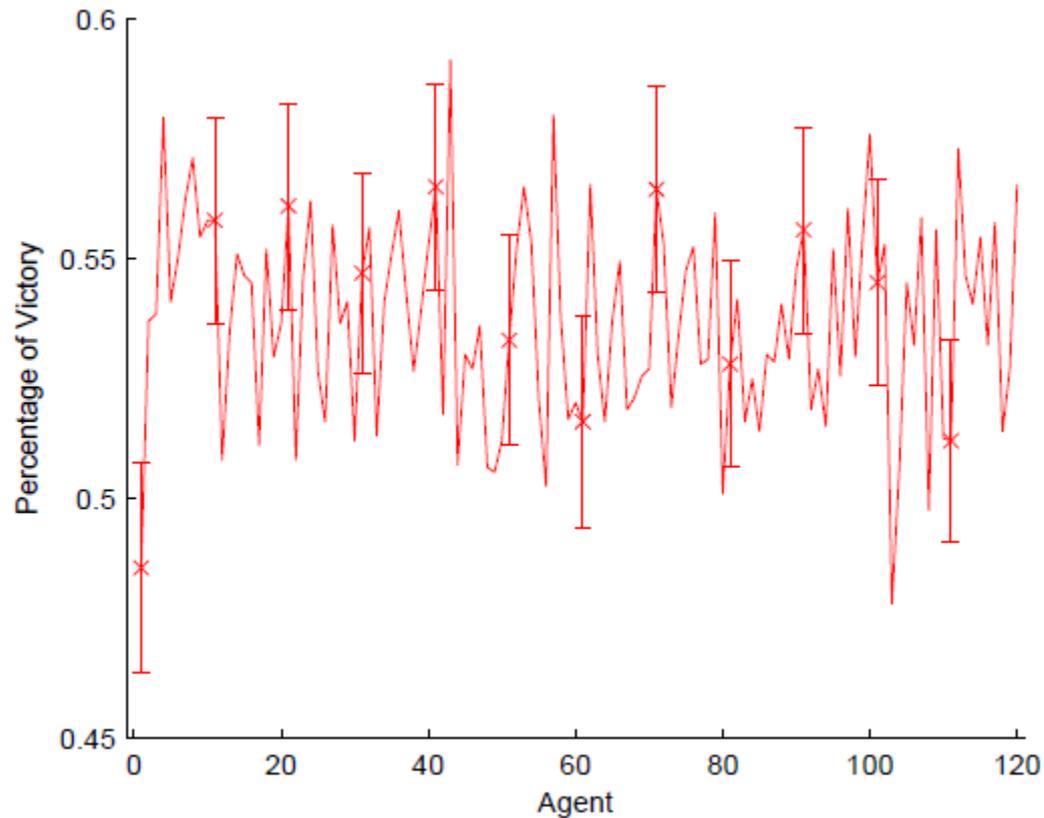
Zufällige Agentenreihenfolge



N	AC	AD	L	P
AD	N	AC	P	L
AD	N	P	AC	L
AD	AC	P	N	L
N	AC	P	L	AD

Backup

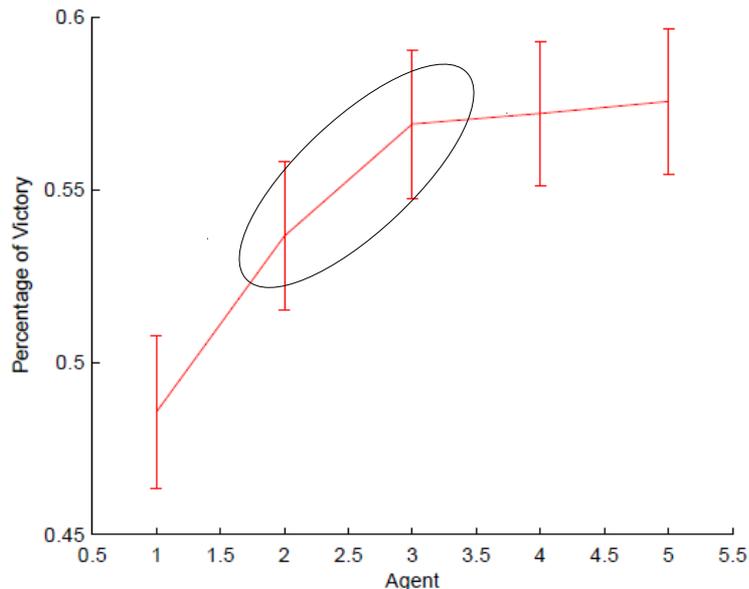
Angepasste Agentenreihenfolge



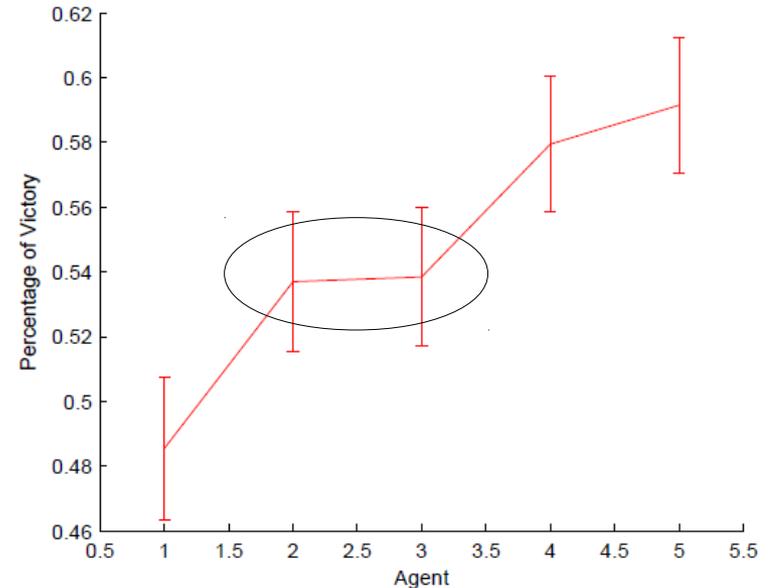
N	AC	AD	L	P
AD	N	AC	P	L
AD	N	P	AC	L
AD	P	L	N	AC
AC	N	AD	L	P

Backup

Performance Vergleich



Agent Number	Percentage of Victory
0	48.50% ± 2.20%
5 (α)	52.85% ± 2.15%
6 (β)	53.60% ± 2.15%
64	57.30% ± 2.15%
70	29.60% ± 1.90%



Agent Number	Percentage of Victory
0	48.55% ± 2.20%
1 (α)	54.40% ± 2.15%
2 (β)	54.55% ± 2.15%
3	57.05% ± 2.15%
42	50.90% ± 2.20%