


# Real-time MCTS (4.7)

## Seminar aus maschinellem Lernen



- Real-time MCTS – Was ist das?
- Beispiele für MCTS in Spielen
  - Tron
  - Ms. Pac-Man

# Real-time MCTS – was ist das?


- Go, Lines of Action, etc Zugbasierte Spiele
- Real-time games (Echtzeitspiele) sind zeitkritisch
- Agent hat wenig Zeit für Berechnungen
- Auch wenn kein Zug durchgeführt wird, geht das Spiel weiter
- Spiele können mitunter nicht deterministisch sein

# Real-time MCTS – wieso MCTS?

- Bisher meist durch Skripte, Trigger, Routinen gelöst
- Motivation: Gute Ergebnisse mit MCTS bei zugbasierten Spielen übertragbar?
- Ziel: Skripte outperformen, oder ähnliches Level erreichen


# Tron – Der Film

- Spiel basierend auf dem Film Tron
- Exkursion Film:
  - 1982 von Walt Disney erschienen
  - Erster Film mit langen Computersequenzen, gilt als Meilenstein in der Computeranimation
  - Kultfilm - Fortsetzung “Tron: Legacy” (2010)
  - Handlung: Programmierer will beweisen, dass Code von ihm ist, wird in Computerwelt materialisiert. Tron ist ein Überwachungsprogramm das “installiert” werden soll. Dort werden Kämpfe ausgetragen → dieses Spiel




# Tron – Das Spielfeld

- Hier: Zwei Spieler
- Spielfeld durch Wand begrenzt.  
MxN groß
- Jedes Feld kann zwei Zustände haben (besetzt, frei)



# Tron – Die Spielregeln

- Spieler können lediglich 90° Bewegungen ausführen
- Wände ersetzen freie Felder nachdem der Spieler drauf war
- Spieler stirbt wenn er auf ein besetztes Feld kommt
- Sieg, Unentschieden, oder Niederlage sind die Möglichen outcomes



# Tron - MCTS

- MCTS mit UCT, da Baumstruktur aufgebaut wird
- Es gibt maximal 3 Züge da nur 2x 90° und geradeaus funktionieren.  
180° → Niederlage
- Rewards: Sieg 1.0; Unentschieden 0.5; Niederlage 0.0
- Durchschnitt wird zurückgegeben (Backpropagation)




# Tron – Game Agent Leitlinien

- Spieler können sich nicht selbst einsperren
- “Survival Mode” falls Spieler eingesperrt wurde
  - Verändert das Spiel in “Single Player” Variante
  - Der längste Weg muss gefunden werden


# Tron – Experiment Spielfelder (Maps)

- Drei Spielfelder: unterschiedliche Problemstellungen

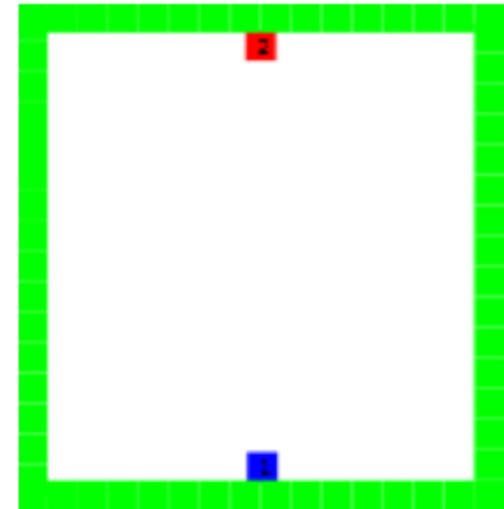
Map A)



Map B)




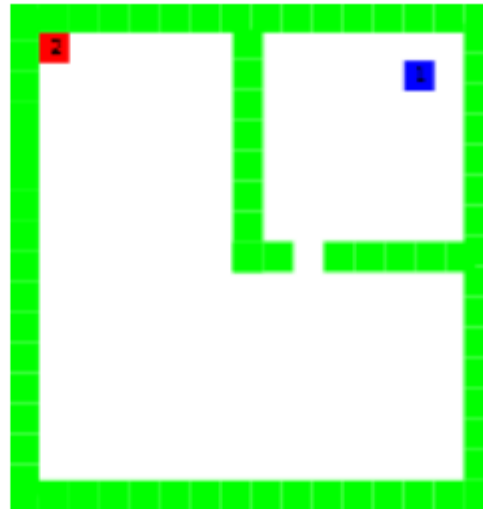

Map C)



# Tron – Map A




- Agent soll erkennen, dass Spieler Eins nach links muss

	Player Two Right	Player Two Left
Player One Right	(1,0)	(0,1)
Player One Left	(1,0)	(0.5,0.5)






# Tron – Map B

- Verlassen des “Käfigs” muss erkannt werden
- Ist im Vorteil weil näher am Zentrum, sollte also fast alle Spiele gewinnen



# Tron – Map C

- “Open Field” Map
- Gleich real-world Maps wahrscheinlich am ehesten



# Tron – Setup Experimente

- Mehrere Agents

- UCB1 (Upper Confidence Bounds applied to Trees)

- $\bar{x}_j + C \sqrt{\frac{\ln(n)}{n_j}}$

- UCB-TUNED

$$\bar{x}_j + \sqrt{\frac{\ln(n)}{n_j} \min \left\{ 1/4, \bar{x}_j^2 - \bar{x}_j^2 + \sqrt{\frac{2 \ln(n)}{n_j}} \right\}}$$

- UCB-E (Bandit)

- $\bar{x}_j + C \sqrt{\frac{\sqrt{n}}{n_j}}$

- Mehrere Zeitintervalle zwischen den “Zügen”


- 100ms – 900ms mit Erhöhungen um 50ms

- Maps werden 20 mal berechnet

- Gespielt wird gegen “Master Player” UCB1 mit 1000ms Rechenzeit

# Tron – Experimente UCB1

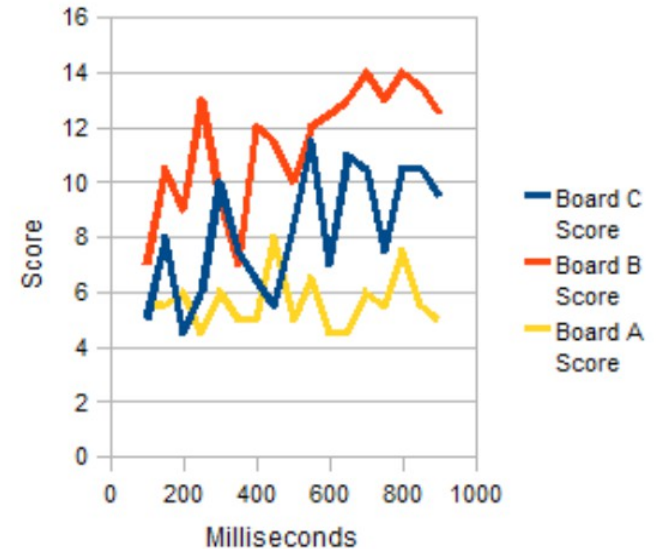
- Reminder:  $\bar{x}_j + C \sqrt{\frac{\ln(n)}{n_j}}$
- Agent erreicht nicht die optimale Performance bei Map B
- Ergebnisse für Map A, C sind eher zufällig



# Tron – Experimente UCB-TUNED



- Reminder: 
$$\bar{x}_j + \sqrt{\frac{\ln(n)}{n_j} \min \left\{ 1/4, \bar{x}_j^2 - \bar{x}_j^2 + \sqrt{\frac{2\ln(n)}{n_j}} \right\}}$$
- Schlechtere Performance als UCB1 für Map B
- Scheint bessere Performance bei Map A, C zu haben (zu kleine Testmenge)

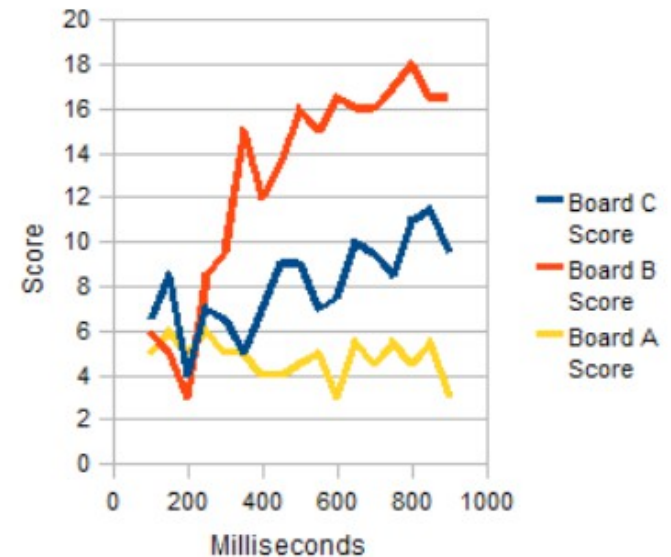




# Tron – Experimente UCB-E



- Reminder:  $\bar{x}_j + C \sqrt{\frac{\ln n}{n_j}}$
- Richtet sich mehr an Exploration, daher ist die Rechenzeit sehr wichtig
- Map A benötigt tiefe Suche, daher kommt wohl schlechtes Ergebnis




# Ms. Pac-Man – Allgemeines I

- Wieso Ms. Pac-Man und nicht Pac-Man?
- Unterschiede in den bekannten Spielfakten
- Geschwindigkeit, Laufwege der Gegner unbekannt.
- Beim essen der Pellets, ändern der Richtung verlangsamt Ms. Pac-Man. Faktor unbekannt




# Ms. Pac-Man – Allgemeines II

- Durch die vielen unbekanntes ist es schwer Regeln zu erstellen (skripten)  
→ Regeln kamen in letzter Zeit an ihre Limits
- Interne Informationen dürfen nicht verarbeitet werden
- Generierung der Informationen mittels Computer Vision



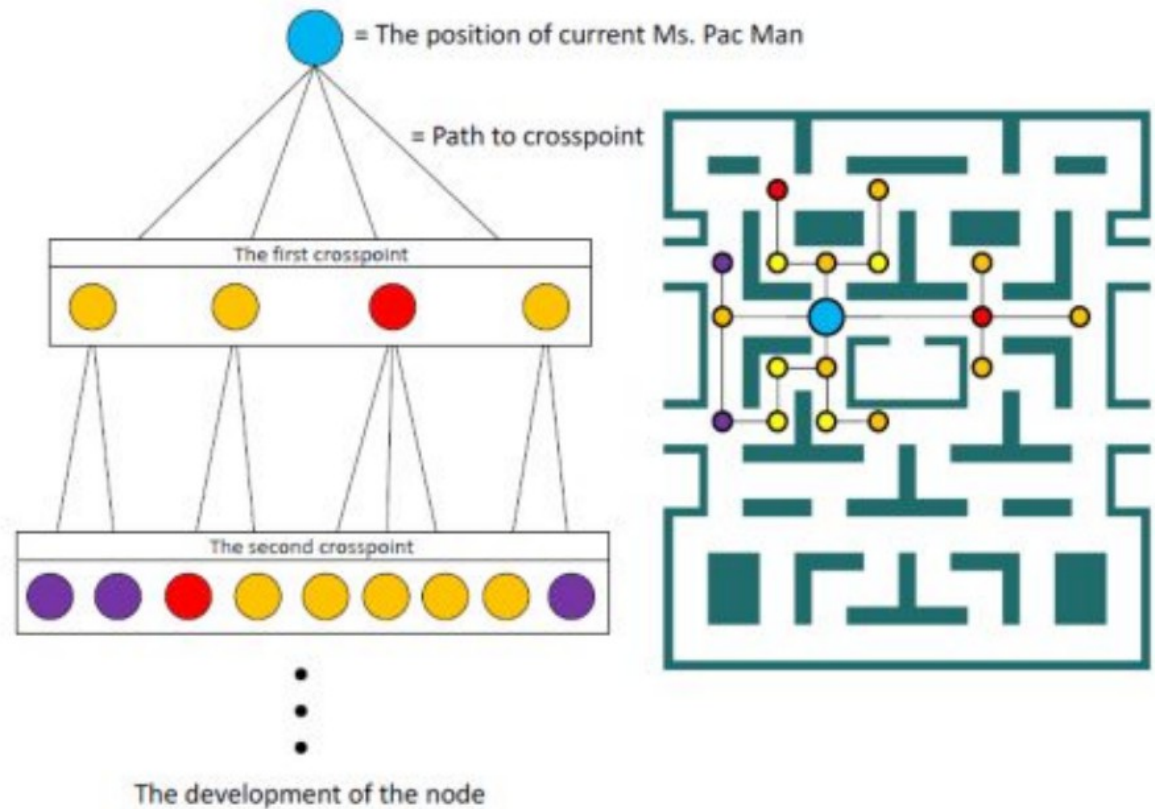
# Ms. Pac-Man – Methodik

- Ziel ist es einen hohen Score zu erreichen. Sammeln der Pellets oder Früchte, Gegner aufessen
- Vermeidung von sog. Pincer Movements (Flankieren der Gegner)



# Ms. Pac-Man – Interne Darstellung I

- Implementierung von C-Paths
- Gegnerbewegungen werden nicht mitmodelliert, doch miteinbezogen (c-paths ohne gegner)
- C-Path muss komplett entlang gelaufen werden.





# Ms. Pac-Man – Interne Darstellung II

- C-Paths bilden nicht die Realität ab
- Realität  $\leftrightarrow$  Simulation
- Gegner werden aggressiver auf Ms. Pac-Man zugehen wenn mehr Pellets vom Feld sind - Typabhängig
- Rewardfunktion: Survival 0-1 ; Pellets gegessen 0-1 ; Ghosts gegessen 0-1  
→ Normalisiert, daher zwischen 0 und 1
- Survival Reward wird der Max-Leaf zurückgegeben

# Ms. Pac-Man - Taktiken

- Survival Mode: Davoneilen der Gegner
- Feeding: Essen der Pellets
- Pursuit: Essen der Gegner
- Wechsel der Taktiken abhängig vom Zustand und eines Thresholds

TABLE II  
SELECTION OF A MOVEMNET PATH

Current Tactics	Selection Method
Survival	Selects a path in which the survival rate is the highest among the paths connected to Ms. Pac-Man.
Feeding	Selects a path which contains more pellets that can be eaten from the ones connected to Ms. Pac-Man and have a survival rate at or higher than the threshold
Pursuit	Selects a path on which more ghosts can be eaten among the paths connected to Ms. Pac-Man with the threshold survival rate or higher

**<Survival> Encounters with a power pellet and a ghost in the blue state are allowed**

**<Feeding> An encounter with a power pellet is allowed, an encounter with a ghost in the blue state is not allowed**

**<Pursuit> An encounter with a power pellet is not allowed, an encounter with a ghost in the blue state is allowed**

# Ms. Pac-Man – Experiment I

- Setup: 300 Simulationen, Vergleich gegen ICE Pambush3
- Ergebnis nach Punktzahl

p	min	max	mean	s.d.
System	6840	37630	24926.5	9085.71
ICE	8620	30660	20574.5	6213.21

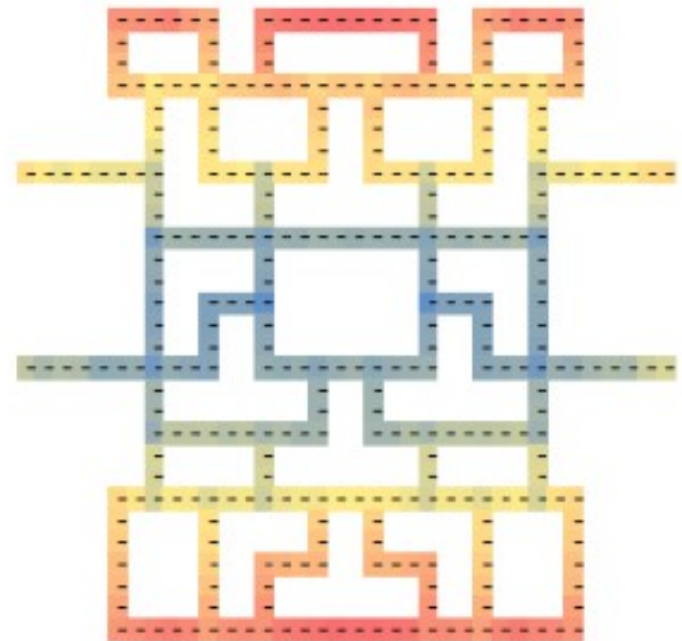
- Ergebnis nach Level

p	min	max	mean	s.d.
System	1	7	4.4	1.497
ICE	1	5	3.4	0.970



# Ms. Pac-Man – Beobachtungen und Verbesserungen Experiment I

- Erreicht besseren Score
- Nicht stabil im Score
- Heatmap der gefährlichen Wege wurde angelegt
- Anpassung der Rewardfunktion an gefährliche Wege
- Pellets auf gefährlichen Wegen sollten zuerst gegessen werden



# Ms. Pac-Man – Experiment II

- Evaluation nach Anpassung der Rewardfunktion
- Ergebnis nach Punktzahl

p	min	max	mean	s.d.
Experiment I	6840	37630	24926.5	9085.71
ICE	8620	30660	20574.5	6213.21
Experiment II	16800	58990	31105.6	11605.57

- Ergebnis nach Level

p	min	max	mean	s.d.
Experiment I	1	7	4.4	1.497
ICE	1	5	3.4	0.970
Experiment II	2	7	4.8	1.361

---

# Ende

- Vielen Dank für die Aufmerksamkeit
- Gibt es noch Fragen?

- N. G. P. Den Teuling, “Monte-Carlo Tree Search for the Simultaneous Move Game Tron,” Univ. Maastricht, Netherlands, Tech. Rep., 2011.
- S. Samothrakis, D. Robles, and S. M. Lucas, “A UCT Agent for Tron: Initial Investigations,” in Proc. IEEE Symp. Comput. Intell. Games, Dublin, Ireland, 2010, pp. 365–371.
- \* D. Robles and S. M. Lucas, “A Simple Tree Search Method for Playing Ms. Pac-Man,” in Proc. IEEE Conf. Comput. Intell. Games, Milan, Italy, 2009, pp. 249–255.
- N. Ikehata and T. Ito, “Monte Carlo Tree Search in Ms. Pac-Man,” in Proc. 15th Game Progr. Workshop, Kanagawa, Japan, 2010, pp. 1–8.