Künstliche Intelligenz

Monte Carlo Tree Search (MCTS)

Dr. Christian Meilicke
Research Group Data and Web Science
Universität Mannheim

Inhalt

- MCTS Historische Entwicklung, Min-Max vs. MCTS
- Grundprinzip als Abfolge von vier Schritten
  - Selection mittels UCT, Expansion, Simulation (“playout”), Backpropagation
- Anwendung auf Würfel- und Kartenspiele
  - Z.B. Determinisierung
- Organisatorisches
  - Programmierprojekt & Bohnen WM

Monte Carlo Tree Search

- Alternatives Verfahren zu Min-Max basierten Verfahren
  - Im folgenden MCTS
- Im allgemeinen anwendbar auf Spiele mit einem sehr hohen Branching Faktor
  - Sehr erfolgreich bei GO
- Kann auf unvollständig beobachtbare Spiele (Karten) oder nicht deterministische Spiele (Würfel) angewendet werden
  - Sehr erfolgreich bei Back-Gammon
- Grundidee: Simuliere eine große Anzahl an vollständig durchgespielten Partieen und schließe auf den besten Zug
  - Benötigt kein Expertenwissen über das Spiel (= keine Heuristik zur Bewertung von Zuständen)

Verstärkendes Lernen
(= Reinforcement Learning)

- Methode des maschinellen Lernens
- Belohnungen (und Bestrafungen) erfolgen als Resultat auf das gezeigte Verhalten
- Agent lernt eine Strategie (= policy), um zukünftige Belohnungen zu maximieren
  - Bei MCTS ist ein Sieg in einer Simulation eine Belohnung, eine Niederlage eine Bestrafung

- MCTS ist ein Paradebeispiel für verstärkendes Lernen
  - Speziell hieran: Anwendung auf Suchbäume

Entwicklung

2006

erste Publikationen die MCTS als Namen verwenden

UCT für die Selektionsphase

2012

Browne et al.: A survey of monte carlo tree search methods

referenziert 240 Papiere

2017

2012 survey
> 800 zitiert

2019

2012 survey
> 1500 zitiert

Min-Max vs MCTS

- Suchbaum beim Min-Max Verfahren

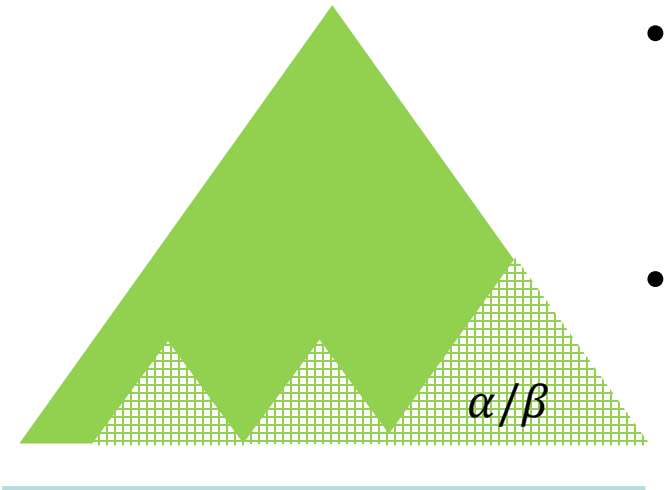

tiefere Ebenen (mit Terminalknoten) werden nicht betrachtet

- Min-Max-Verfahren ≈ tiefenbeschränkte Suche
- Suchbaum vollständig ablaufen bis zu einer bestimmten Ebene
  - Wie bei einer Breitensuche
- Heuristik wird meist auf Nicht-Terminalzustände angewendet und hochpropagiert

Min-Max vs MCTS

- Suchbaum bei MCTS

- Suchbaum nicht gleichmäßig balanciert = Tiefe variiert
  - Ähnelt der A*-Suche
- Heuristikfunktion wird ersetzt duch aggregierte Simulationsergebnisse (=Statistik)
- Statistik entscheidet welcher Bereich genauer untersucht wird

Datenstruktur / Statistik

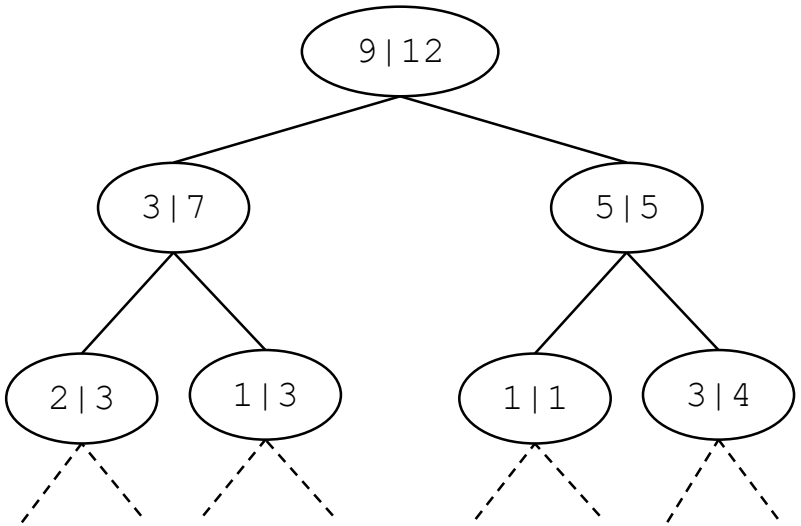

Legende:

Siege A | Siege B

basierend auf den von diesem Knoten aus gespielten Simulationen

Summe der Kindattribute = Werte im Elternknoten + 1 (Ausnahme: Wurzel)

- Hinweis: Darstellung leicht modifiziert gegenüber der üblichen Beschreibung
- Siege (und Niederlagen) ergeben sich aus simulierten Spielen
  - Die Simulationen starten von dem jeweiligen Knoten oder seinen Kindern

Phasen

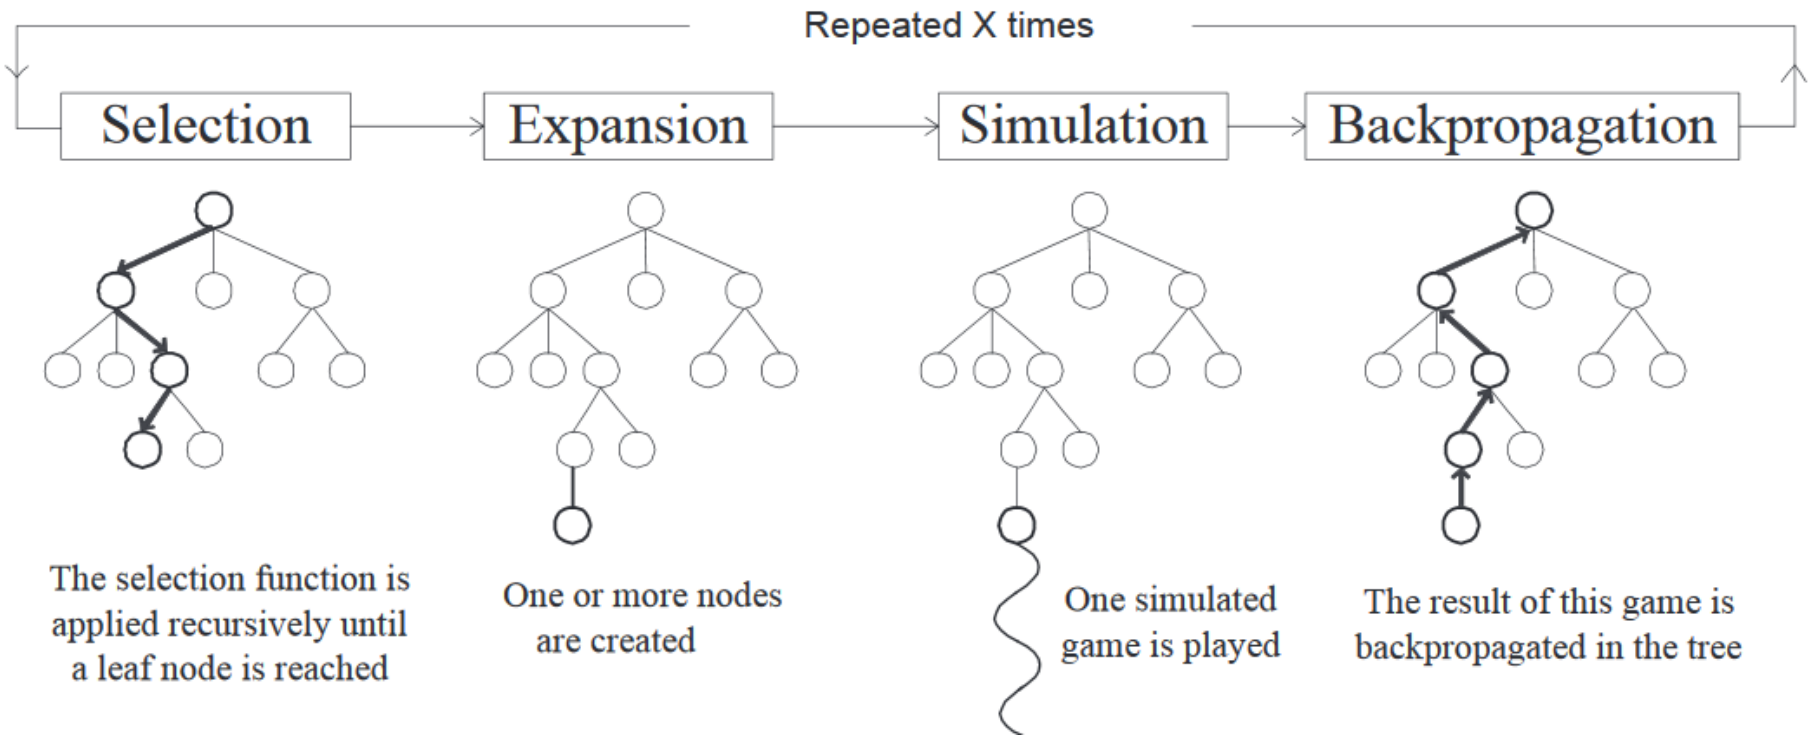

Taken from CHASLOT et al.: PROGRESSIVE STRATEGIES FOR MONTE-CARLO TREE SEARCH, 2007.

Phasen

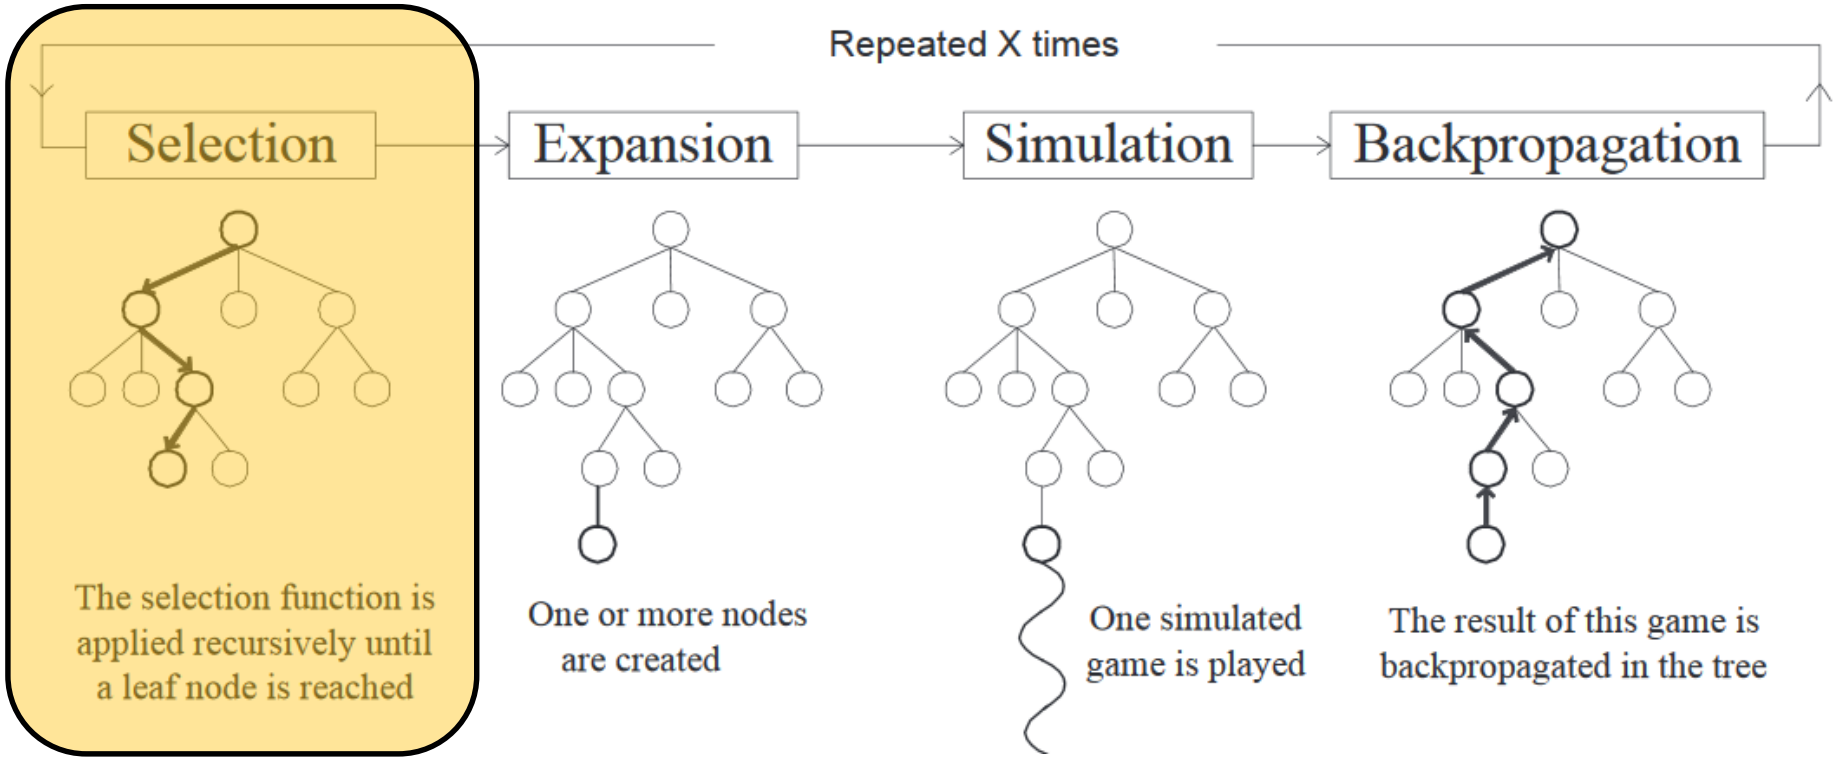

Taken from CHASLOT et al.: PROGRESSIVE STRATEGIES FOR MONTE-CARLO TREE SEARCH, 2007.

Selektion: UCB und UCT

- UCB = Upper Confidence Bound
- UCT = Upper Confidence Bound applied to Trees

- UCB Algorithmus bzw. Formel wurde ursprünglich angewendet auf das „Multiarmed Bandit Problem“
  - Aus mehreren einarmigen Banditen kann gewählt werden
  - Was ist die beste Taktik gegeben die bisherigen Erfahrungen

UCB

Umfrage: A, B, C oder D

3 Spiele
∅ = +0.3

10 Spiele
∅ = +0.4

1 Spiel
∅ = -0.3

5 Spiele
∅ = -0.1

- Exploration-Exploitation Dilemma
  - Exploration = Erforsche durch Ausprobieren welches der beste Automat ist
  - Exploitation = Spiele am „besten“ Automaten um Gewinn zu machen

- Wann „explore“ und wann „exploit“?

UCB

3 Spiele	10 Spiele	1 Spiel	5 Spiele
∅ = +0.3	∅ = +0.4	∅ = -0.3	∅ = -0.1

- v_k = Durchschnittsgewinn am Automaten k
- C = Parameter (je höher C umso wichtiger wird Exploration)
- n = Anzahl aller Spiele
- n_k = Anzahl der Spiele an Automat k
- $UCB_k = v_k + C * \sqrt{\frac{\log n}{n_k}}$

log hier = logarithmus zur basis e (natürlicher logarithmus)

UCB

C=1

- v_k = Durchschnittsgewinn am Automaten k
- C = Parameter (je höher C umso wichtiger wird Exploration)
- n = Anzahl aller Spiele
- n_k = Anzahl der Spiele an Automat k
- $UCB_k = v_k + C * \sqrt{\frac{\log n}{n_k}}$

UCB

C=1

- v_k = Durchschnittsgewinn am Automaten k
- C = Parameter (je höher C umso wichtiger wird Exploration)
- n = Anzahl aller Spiele
- n_k = Anzahl der Spiele an Automat k
- $UCB_k = v_k + C * \sqrt{\frac{\log n}{n_k}}$

Wähle Automat mit dem höchsten UCB Wert und spiele dort weiter!

UCT

- Anwendung auf Bäume
- Entscheidungen an den inneren Knoten

- v_k = Anteil der gewonnenen Simulationen am Knoten k
  - **Aus Sicht des Spieler der den Zug macht, der zu Knoten k führt**
- C = Parameter (je höher C umso wichtiger wird Exploration)
- n_p = Anzahl der von k‘s Elternknoten gespielten Simulationen
- n_k = Anzahl der von Knoten k gespielten Simulationen
- $UCB_k = v_k + C * \sqrt{\frac{\log n_p}{n_k}}$

UCT

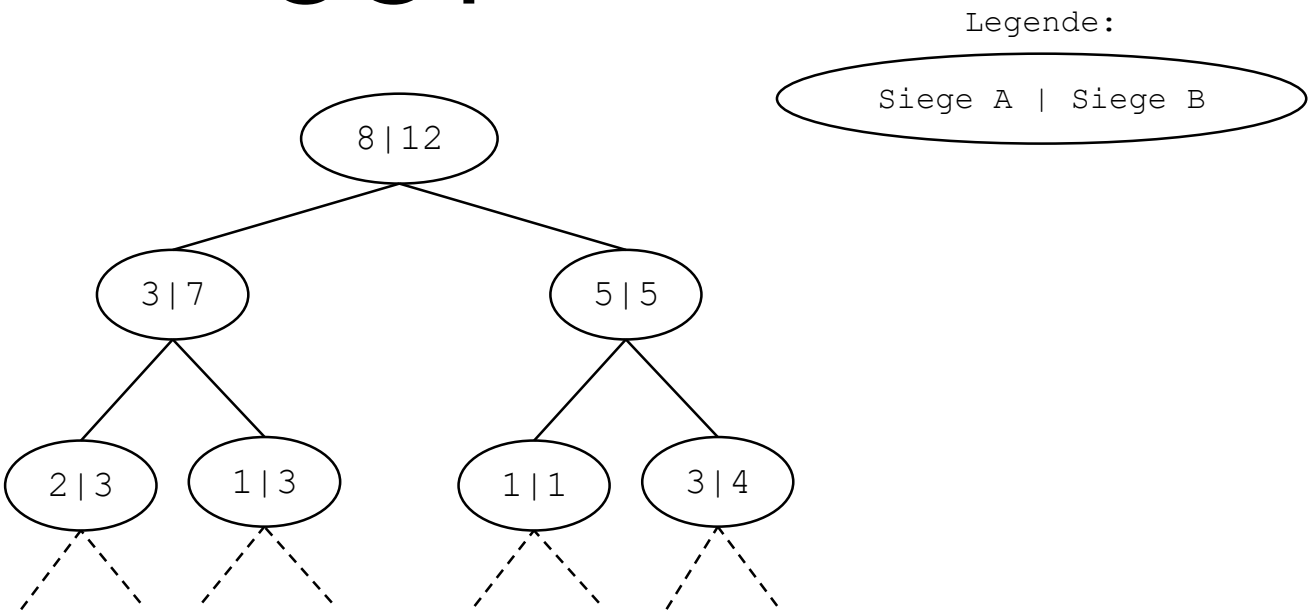

v_k = Anteil der gewonnenen Simulationen am Knoten k

C = Parameter (je höher C umso wichtiger wird Exploration)

n_p = Anzahl der von k‘s Elternknoten aus gespielten Simulationen

n_k = Anzahl der von Knoten k aus gespielten Simulationen

$$\boldsymbol{UCB_k = v_k + C * \sqrt{\frac{log\, n_p}{n_k}}}$$

UCT

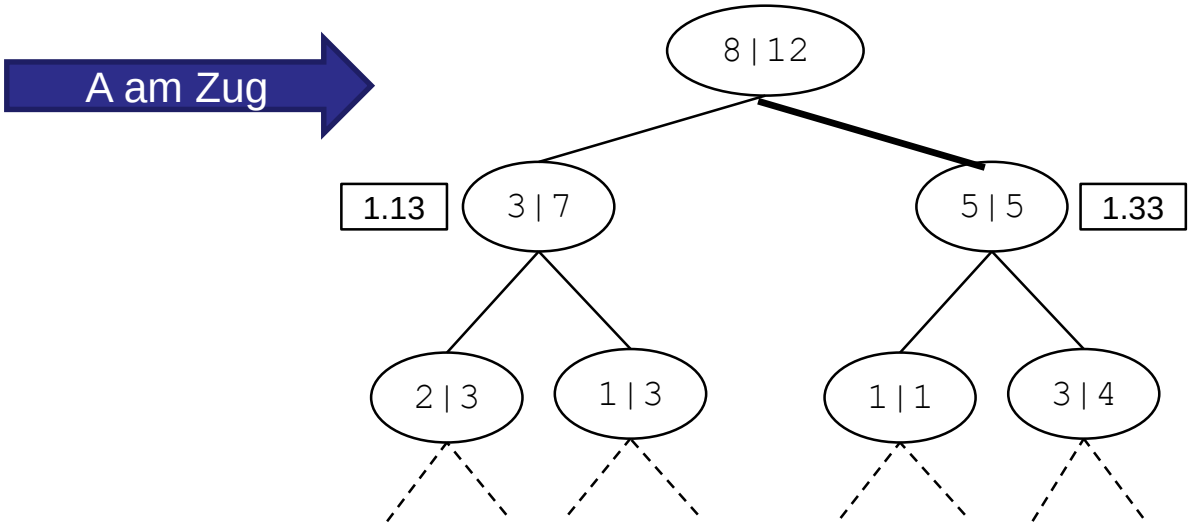

v_k = Anteil der gewonnenen Simulationen am Knoten k

C = Parameter (je höher C umso wichtiger wird Exploration)

n_p = Anzahl der von k‘s Elternknoten aus gespielten Simulationen

n_k = Anzahl der von Knoten k aus gespielten Simulationen

$$UCB_k = v_k + C * \sqrt{\frac{log\, n_p}{n_k}}$$

UCT

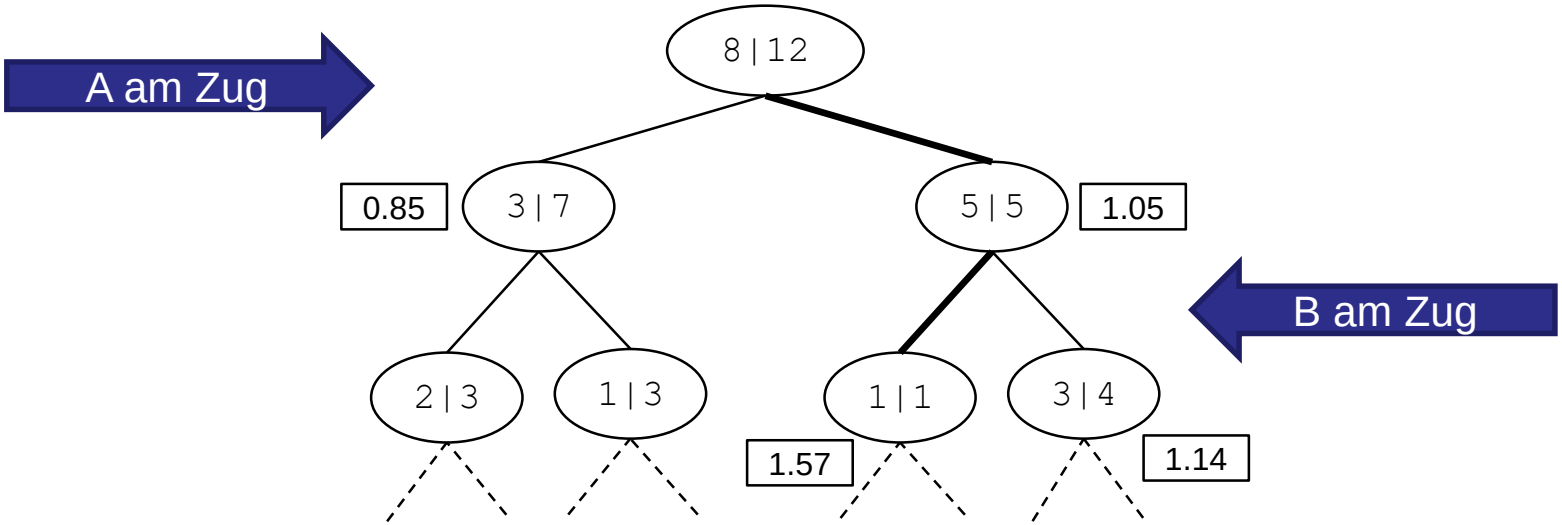

v_k = Anteil der gewonnenen Simulationen am Knoten k

C = Parameter (je höher C umso wichtiger wird Exploration)

n_p = Anzahl der von k‘s Elternknoten aus gespielten Simulationen

n_k = Anzahl der von Knoten k aus gespielten Simulationen

$$UCB_k = v_k + C * \sqrt{\frac{log\, n_p}{n_k}}$$

Wahl von C

- C ist ein Parameter, den man in der Regel experimentell ermittelt
  - Lasse KIs mit C=1, C=1.5, C=2, C=2.5, ... sehr oft gegeneinander antreten
  - Eventuell auch gegen andere KIs (z.B. Min-Max basiert)
  - Wähle den C-Wert, der am besten abschneidet

- Gute Ergebnisse können für $\sqrt{2}$ erwartet werden
  - Kocsis & Szepesvari: Bandit based monte-carlo planning. ECML, 2006.

Phasen

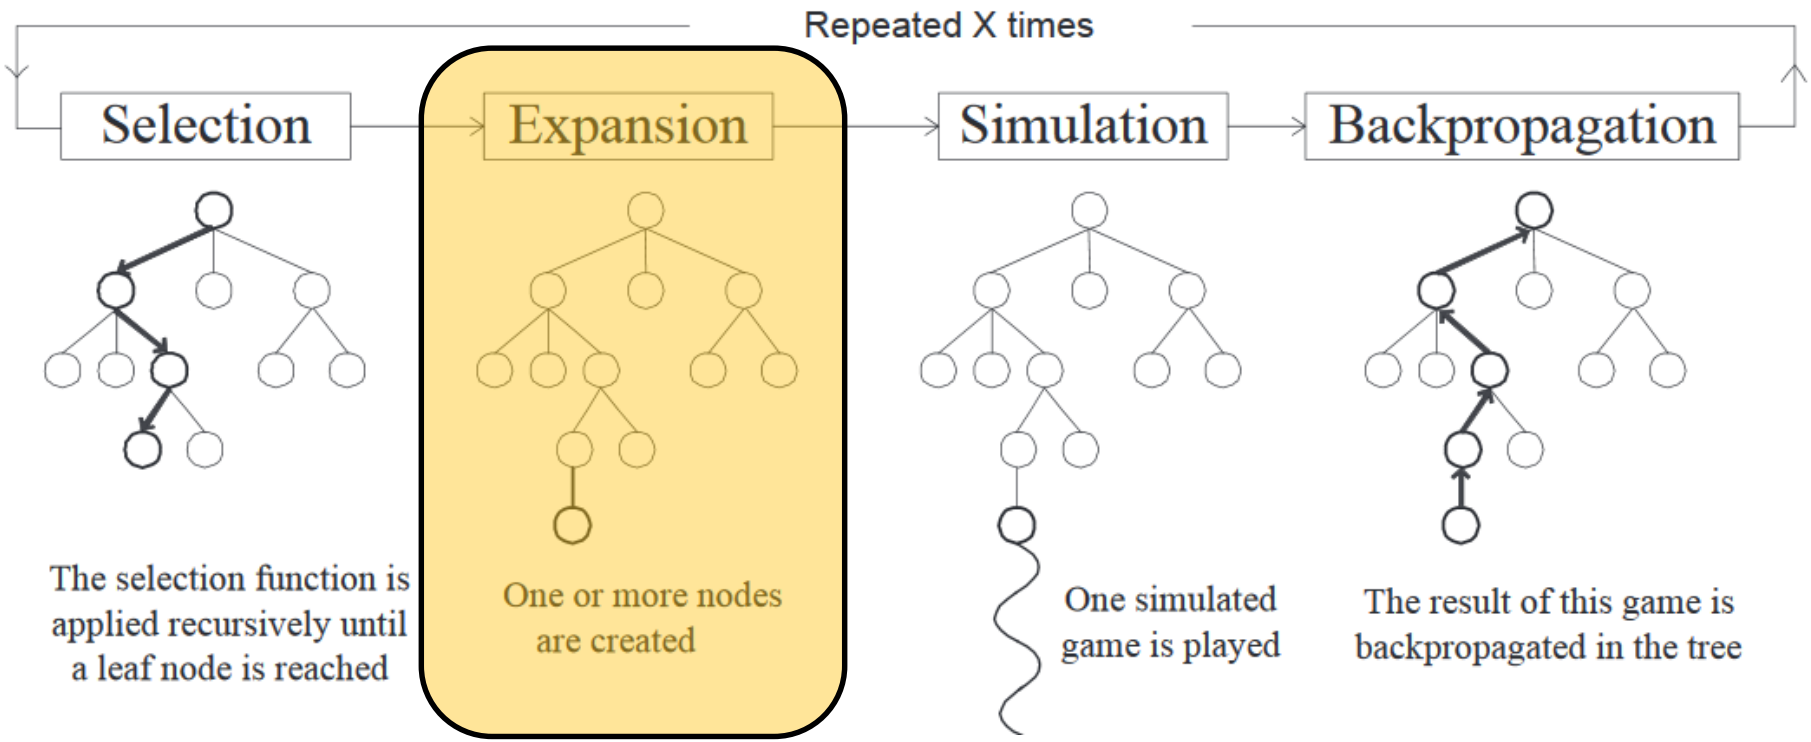

Taken from CHASLOT et al.: PROGRESSIVE STRATEGIES FOR MONTE-CARLO TREE SEARCH, 2007.

Expansionsregeln

- Innere Knoten, bei denen alle Kinder bereits expandiert sind, können nicht weiter expandiert werden
  - Auswahl (Selection) eines Kindes per UCT

- Blattknoten ohne Kinder
  - Variante 1:
    - Erzeuge alle Kinder, initialisiere diese mit 0|0 und führe für jeden Kindknoten eine Simulation durch
  - Variante 2:
    - Erzeuge einen zufällig ausgewählten Kindknoten, initialisiere diesen mit 0|0 und führe eine Simulation durch

Sonderregel

- Innere Knoten, bei denen mindestens ein Kind aber noch nicht alle Kinder expandiert wurden
  - Kann es nur in Variante 2 geben!
  - Erzeuge einen weiteren zufällig ausgewählten Kindknoten, initialisiere diesen mit 0|0 und führe eine Simulation durch

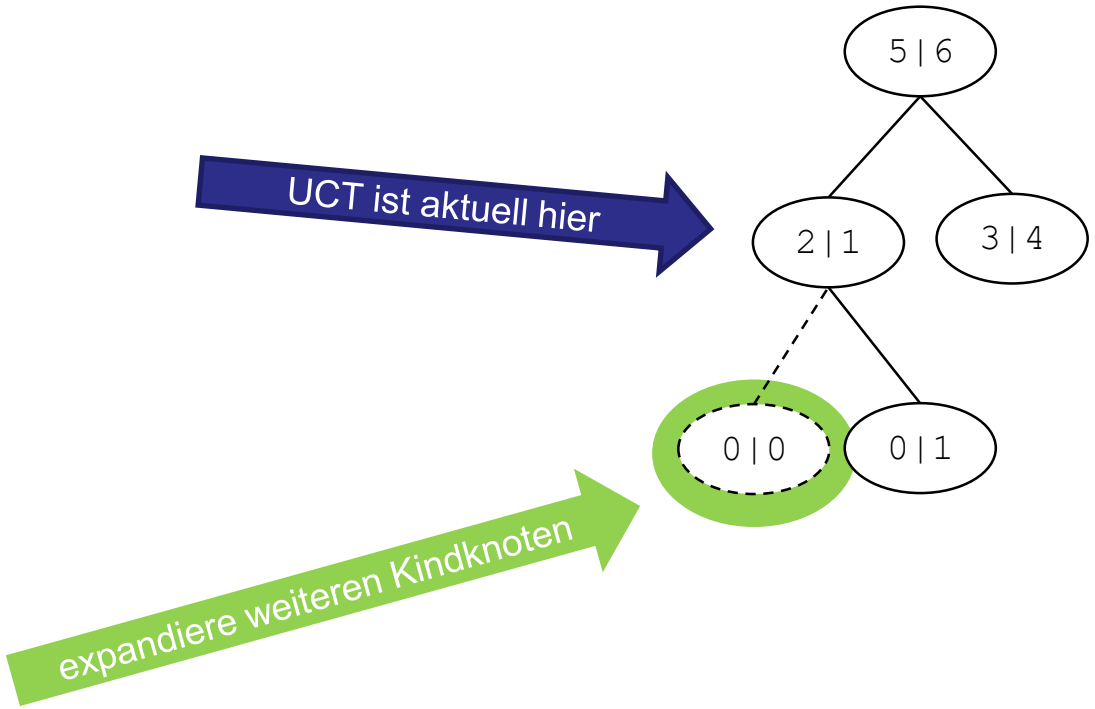

Vergleich

- Variante 1:
  - Es werden immer alle Kindknoten erzeugt
  - Kann bei hohem Branchingfaktor teuer sein
- Variante 2:
  - Nachdem mehrere Kindknoten (aber nicht alle) erzeugt wurden, kann der Wert das Elternknoten so schlecht werden, dass dieser nicht mehr besucht wird
  - Fokus geht auf anderen Bereich des Baums
  - Verbleibende Kindknoten werden nicht mehr expandiert

Variante 2 bei hohem Branchingfaktor sinnvoll

Phasen

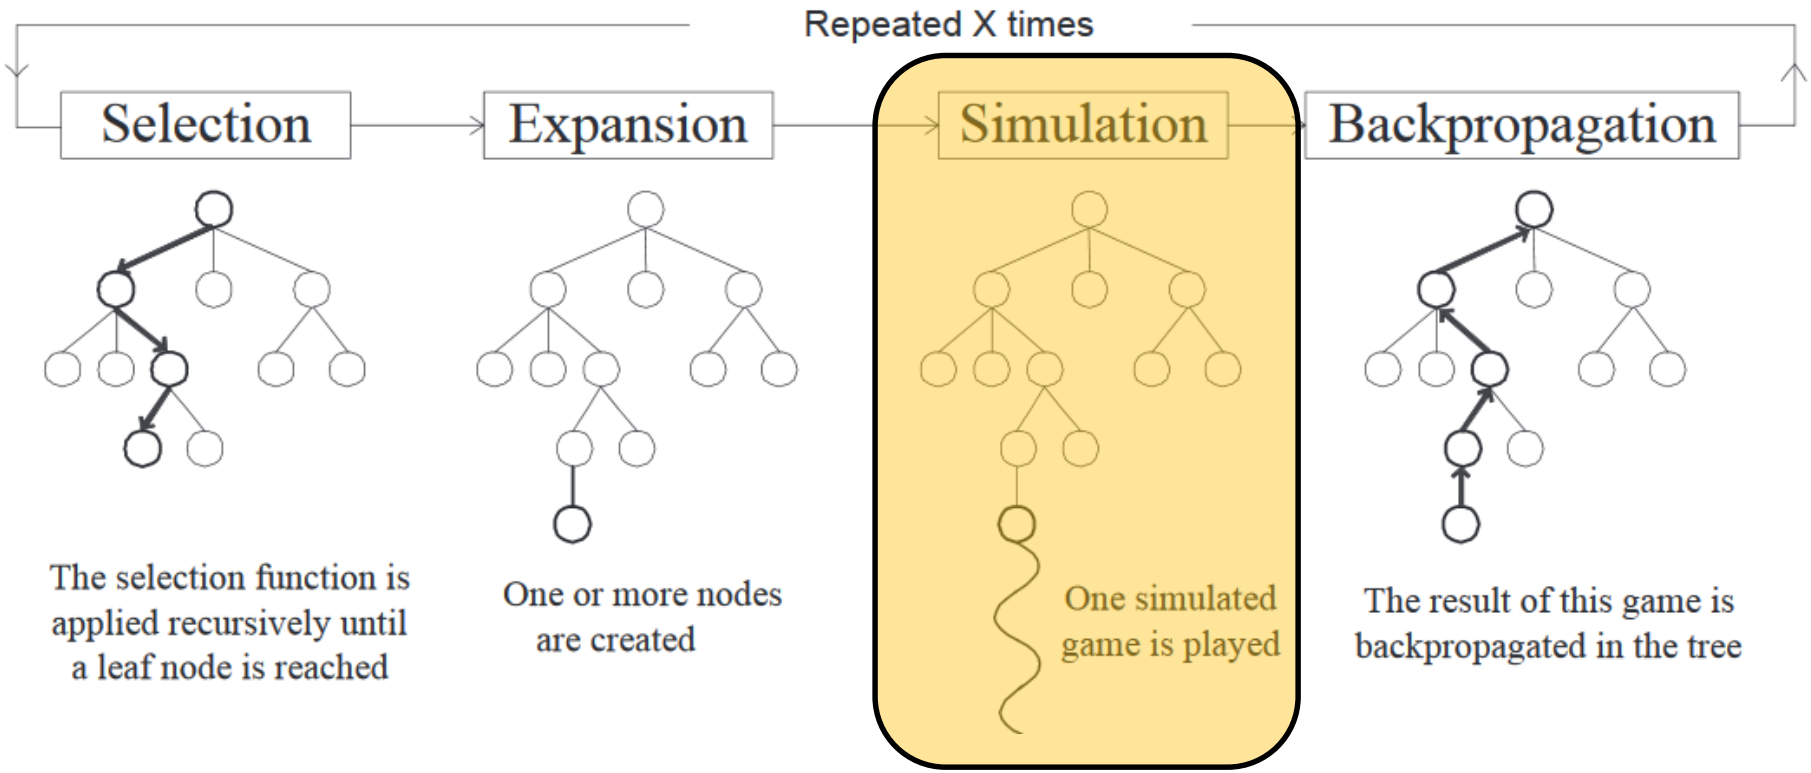

Taken from CHASLOT et al.: PROGRESSIVE STRATEGIES FOR MONTE-CARLO TREE SEARCH, 2007.

Simulation

- Light Playout
  - In der Simulation werden vollkommen zufällige Züge gemacht
- Heavy Playout
  - Nicht (ganz) zufällig, stattdessen
    - Einfache Heuristik
    - Zufall gemischt mit Heuristiken
    - Min-Max KI mit geringer Suchtiefe
    - ...
- Vorsicht beim Heavy Playout mit Heuristik
  - Werden dabei systematisch gute Zugmöglichkeiten übersehen, so führt dies zu geringer Spielstärke

Light vs. Heavy Playout

- Heavy Playout ist besser als Light Playout bei gleicher Anzahl an Iterationen
  - Klar, zufälliges Spiel wird in der Realität nicht auftauchen
  - Statistiken, die hierauf basieren sind nicht aussagekräftig
- Aber: Heavy Playout ist in der Regel (deutlich) teurer, d.h. eine Simulation dauert (viel) länger
- Abwägen: Sind 10 vernünftige Simulationen besser als 1000 zufällige?
  - Auch hier gilt: Kann letztlich nur experimentell bestimmt werden

Ausspielen vs. Abbrechen

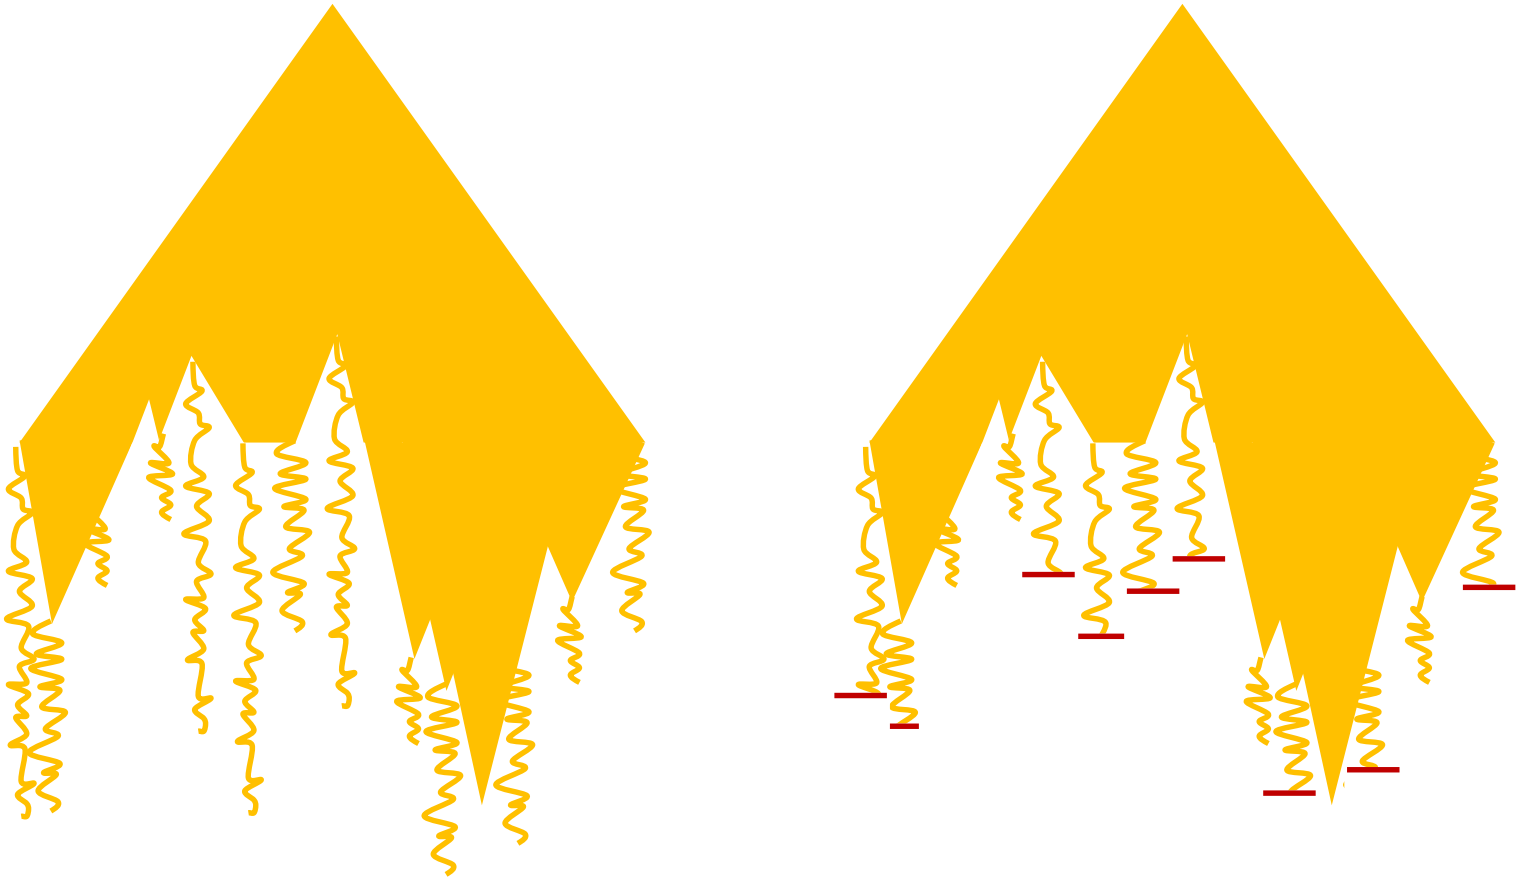

Ausspielen vs. Abbrechen

- Bei Spielen, die erst nach vielen Zügen beendet sind, kann es Sinn machen, die Simulation abzubrechen

- Bei Abbruch ⇒ Anwendung einer Heuristik
  - Entspricht (ungefähr) der Heuristik beim Min-Max Verfahren
  - Entweder, um dann Sieg oder Niederlage zu schätzen
  - Oder um Heuristikwert „nach oben zur propagieren“

- Wann genau kommt die Heuristik zum Einsatz?
  - Wenn bestimmte Suchtiefe erreicht ist oder,
  - Wird alle m Züge berechnet
    - Klarer Ausschlag wird als Sieg oder Niederlage gewertet
    - Kein klarer Ausschlag => Simulation fortführen

Phasen

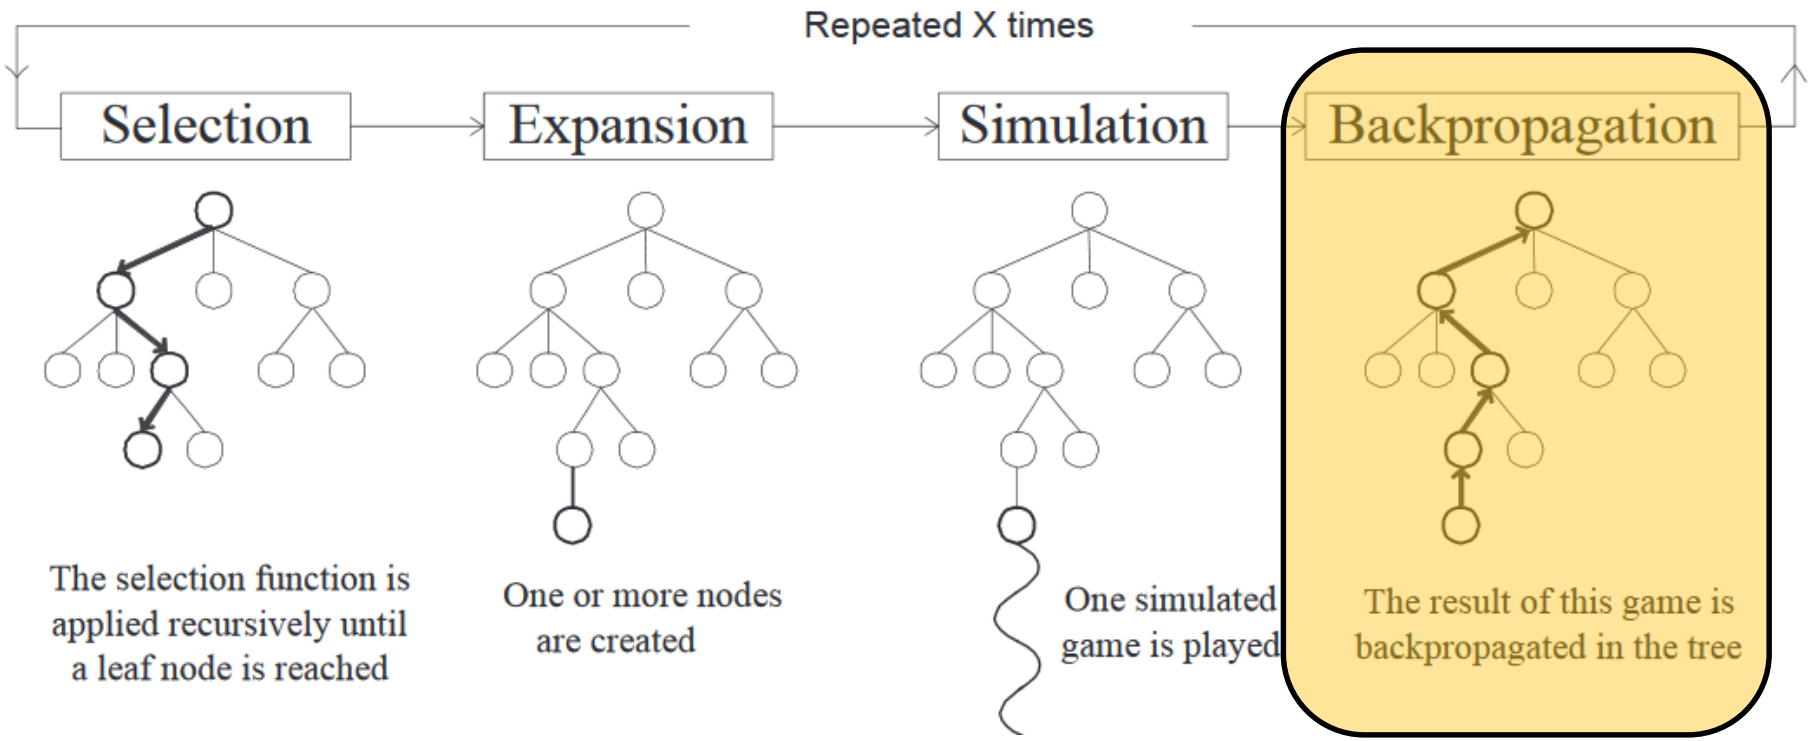

Taken from CHASLOT et al.: PROGRESSIVE STRATEGIES FOR MONTE-CARLO TREE SEARCH, 2007.

MCTS: Backpropagation

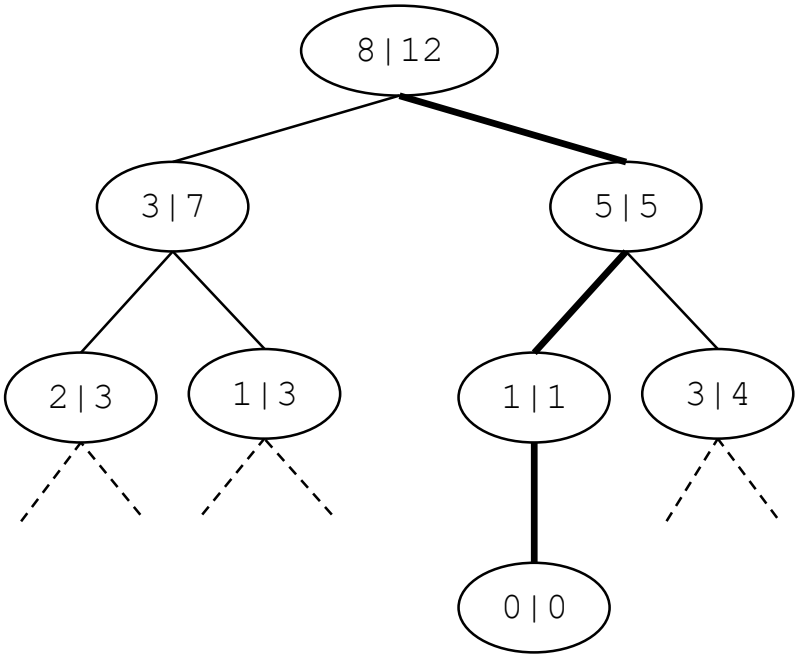

MCTS: Backpropagation

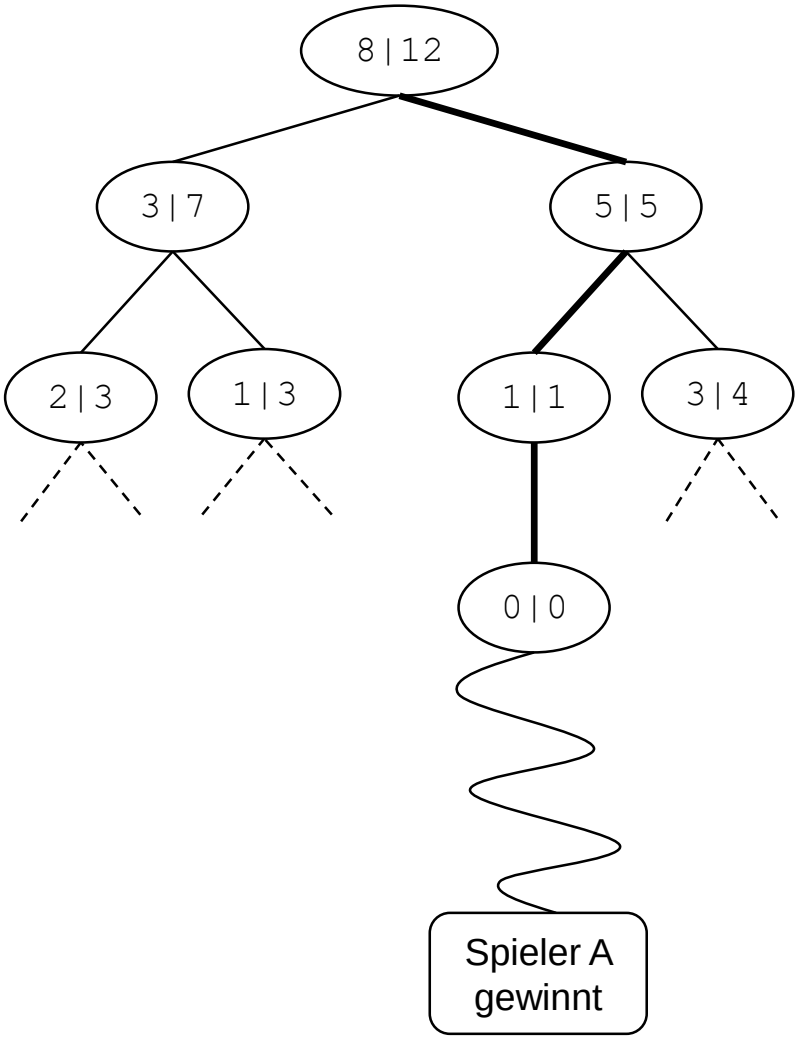

MCTS: Backpropagation

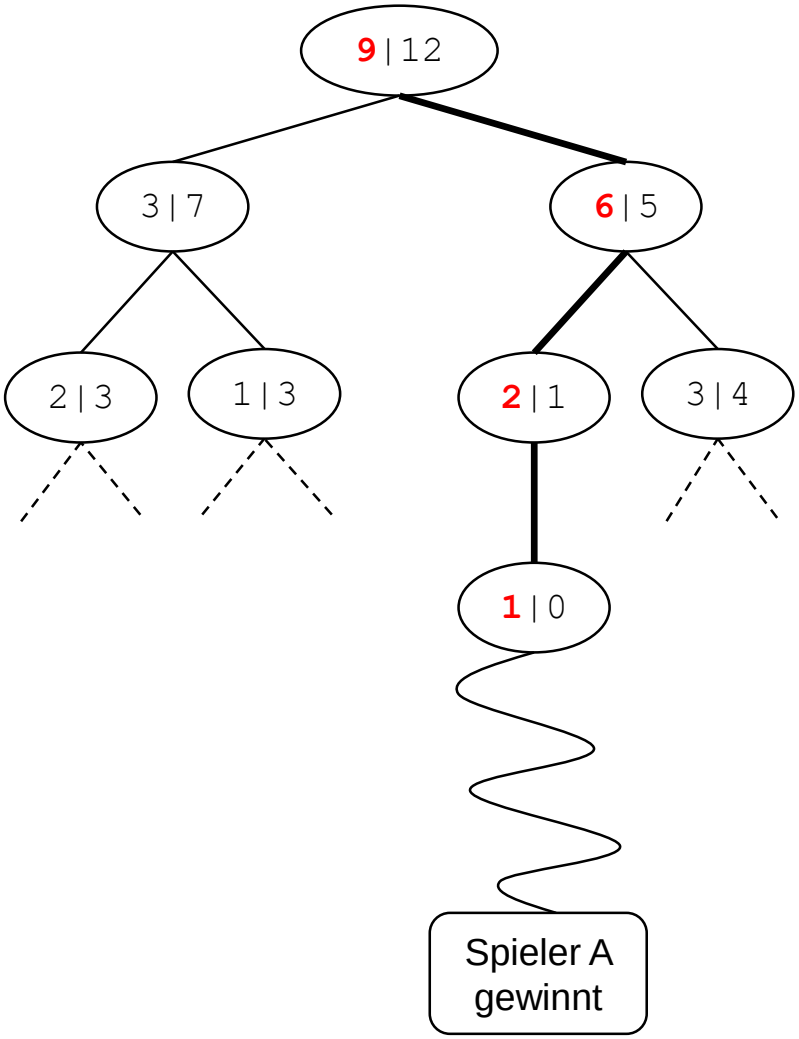

Phasen

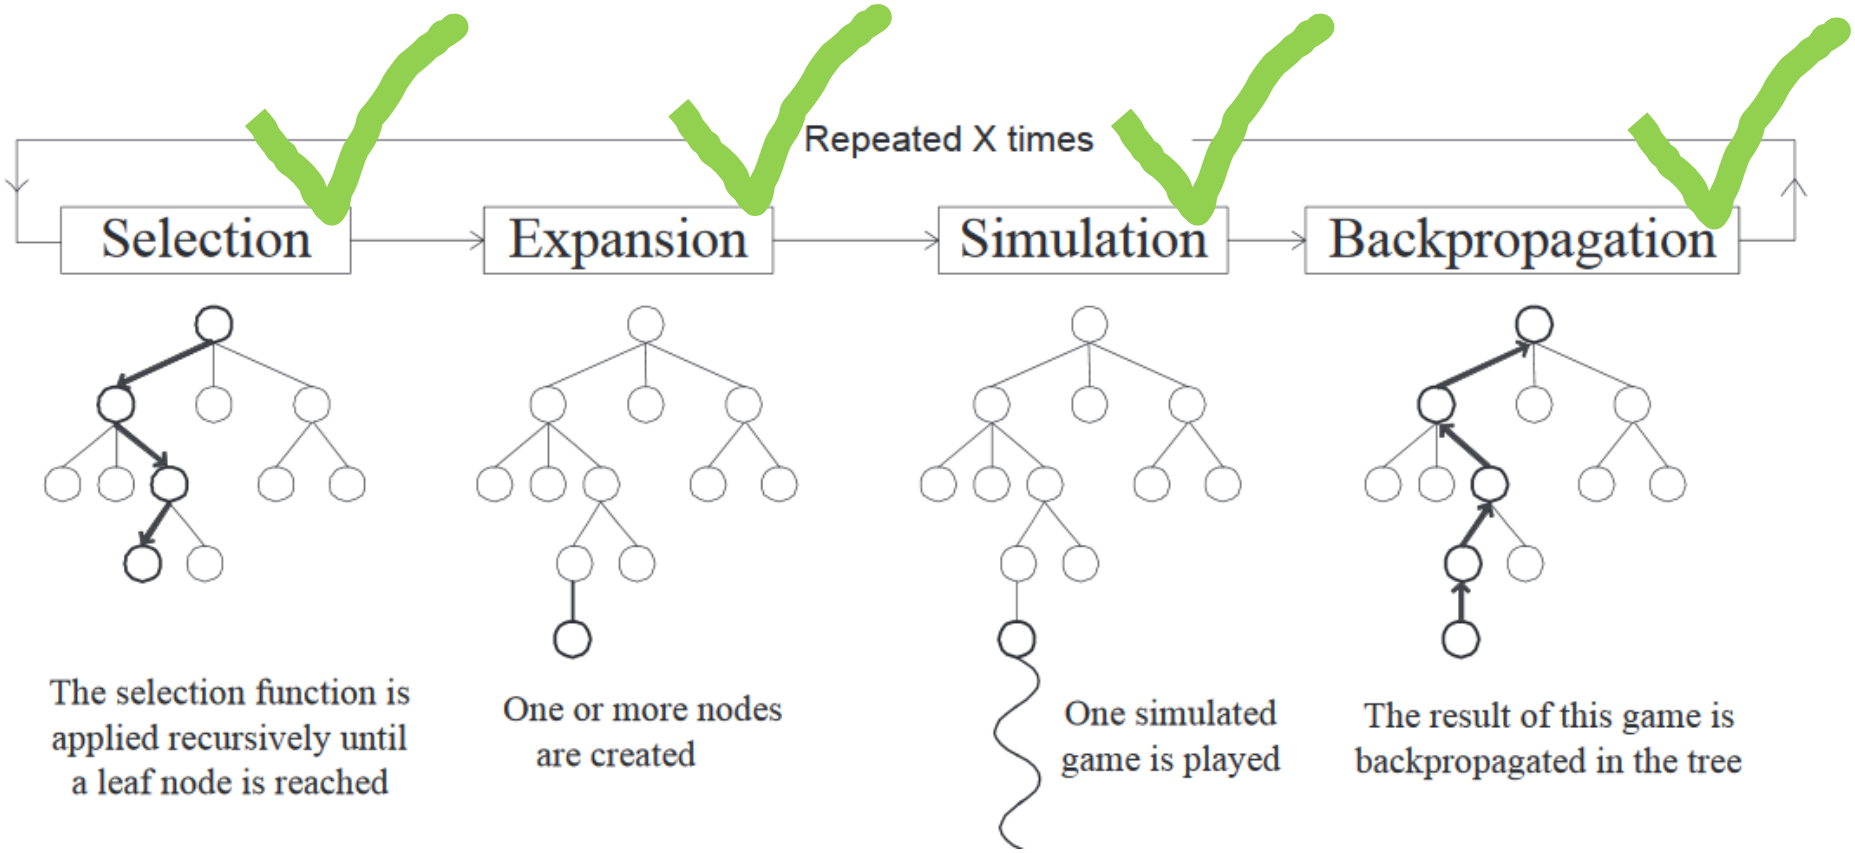

Taken from CHASLOT et al.: PROGRESSIVE STRATEGIES FOR MONTE-CARLO TREE SEARCH, 2007.

Auswahl der Handlung

- Bei Sieg/Niederlage Spielen wird die Handlung gewählt, die zu dem Knoten mit den meisten Besuchen führt
  - Ist in der Regel auch der Knoten mit der höchsten Gewinnrate

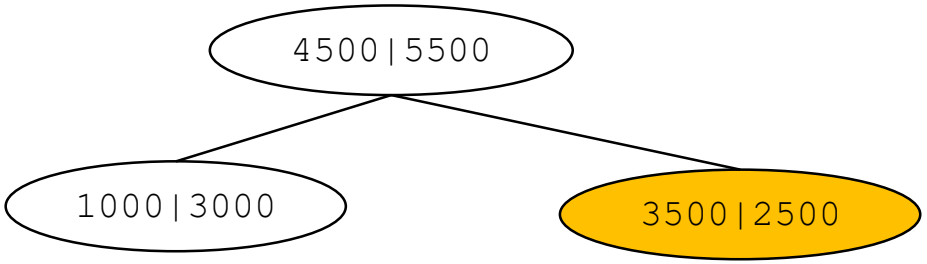

- Eventuell andere Strategie bei Spielen mit verschiedenen Ausgängen
  - Ziel kann es sein ein möglichst geringes Risioko einzugehen
  - Andere „Statistiken“ müssen gespeichert werden

Zwischenfazit

- Verfahren ähnelt bis zu einem gewissen Grad dem Min-Max Verfahren
  - Propagieren der Simulationsergebnisse
    ~ Propagieren der Heuristikwerte bei Min-Max
  - UCT Entscheidungen (wenn Exploration ignoriert wird)
    ~ Abwechselnde Zugwahl durch Min/Max Spieler

- Unterschiede
  - Vielversprechende Bereiche im Suchbaum werden intensiver durchsucht
  - Bei Light-Playout wird keinerlei Wissen über das Spiel benötigt
  - Erweiterbar auf partiell beobachtbare Spiele, z.B. Kartenspiele

Nicht-deterministische und nur partiell beobachtbare Spiele

- Problem bei Kartenspielen: Karten des Gegners unbekannt (ebenso die Karten auf dem Stapel)
  - Zugmöglichkeiten des Gegners sind somit unbekannt
  - Bei der Expansion und Simulation ein Problem

- Problem bei Würfelspielen: Wir wissen nicht wie die Würfel des Gegners fallen werden
  - Zugmöglichkeiten des Gegners sind somit unbekannt
  - Bei der Expansion und Simulation ein Problem

Erinnerung

- Bisher hatten wir nur ExpectiMax kennengelernt
  - Min-Max mit Erweiterung um Chance Nodes
  - Suchraum explodiert, kann oft nicht effizient angewendet werden

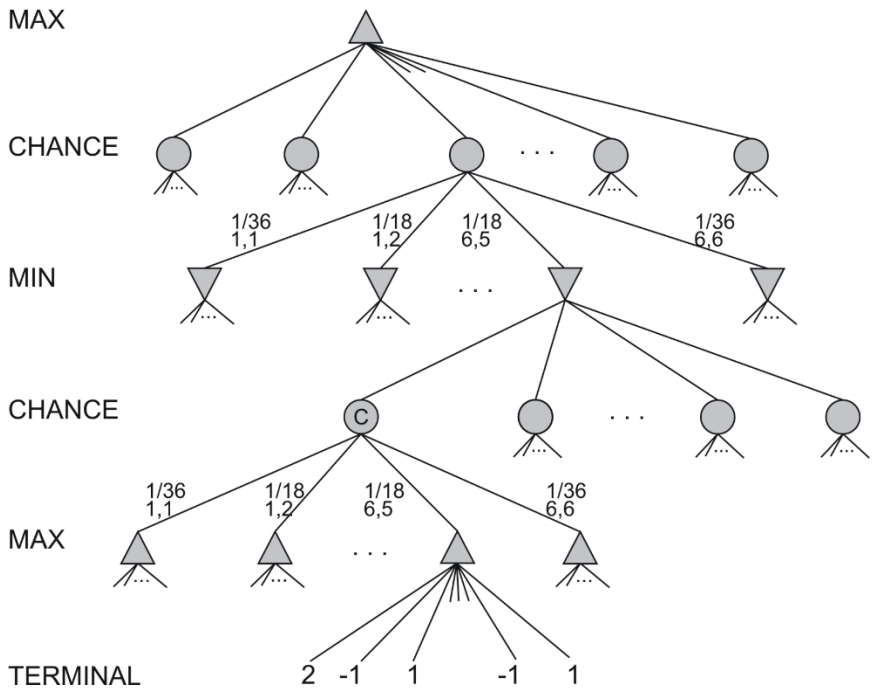

Einfacher Ansatz: Determinisierung

- Würfelspiel: Erzeuge n zufällige Abfolgen von Würfelergebnissen
- Kartenspiel: Erzeuge n zufällige Verteilungen der verbleibenden Karten auf Gegner und Stapel

- Wende MCTS m-mal auf jedes der n vollständig beobachtbaren und deterministischen Probleme an

- Aggregiere die erste Ebene der Knoten der m MCTS Bäume und entscheide auf dieser Basis
  - Die erste Ebene hat bei allen Bäumen dieselben Knoten
  - Erst danach unterscheiden sich die Bäume

- Auch bekannt als „Perfect Information Monte“ Carlo (PIMC)

Unvollständige Information vs. Nicht-Deterministisch

- Würfelspiel ist nicht deterministisch
  - Weder A noch B wissen, wie die Würfel im weiteren Spielverlauf fallen
  - **Der Zugang zu diesem Wissen ist prinzipiell nicht gegeben**

- Beim Kartenspiel sind nicht alle relevanten Informationen bekannt
  - A kennt eigene Karten und hat Vermutungen über die Karten von B
  - B kennt eigene Karten und hat Vermutungen über die Karten von A

- Grundlegender Unterschied zwischen Würfel- und Kartenspiel
  - Beim Kartenspiel sind möglichst umfangreiche und korrekte Vermutungen wichtig
  - Spezielle Erweiterungen/Anpassungen notwendig
    1. Um Vermutungen zu **generieren**
    2. Um Vermutungen **auszunutzen**

Modell des Gegners

- Vergangene Züge des Gegners erlauben (probabilistische) Schlussfolgerungen über die Hand des Gegners

1

- Beispiel:
  - Gegner hätte wichtigen Stich verhindern können, wenn er Karte X oder Y gehabt hätte
  - Er hat X oder Y nicht gelegt, und damit den Stich verloren
  - Also: Er hat (wahrscheinlich) weder X noch Y

- Kann bei der Determinisierung ausgenutzt / berücksichtigt werden
  - Nur solche Determinisierungen erzeugen, die zum Wissen über den Gegner passen
  - Beispiel: Verwerfe Determinisierung bei der Gegner X oder Y hat

2

Offene Probleme

- Es gibt Aktionen, die ausgeführt werden, um Wissen zu erhalten
  - Beispiel, Spiel, bei dem man Stiche sammelt: Eine niedrige Karte wird angespielt, um zu sehen ob der Gegner noch Trumpf hat
  - Solche Aktionen können unmöglich in einer Determinisierung „modelliert werden“
- Strategy Fusion: Unvereinbare Strategien werden vermischt
  - In einer Determinisierung kann eine zentrale Strategie gespielt werden, die unvereinbar ist mit der Strategie, die in einer anderen Determinisierung gespielt wird (und dort zu den besten Ergebnissen führt)
  - Dennoch werden die resultierenden Statistiken aggregiert
- Unnötige (doppelte) Berechnungen
  - Zwei Determinisierungen können sich in relativ unwesentlichen Teilen unterscheiden
  - Teile der MCTS Bäume werden werden zweimal zweimal identisch aufgebaut
- **Bestimmte Aspekte der „Unvollständigen Information“ können nicht durch Determinisierung abgebildet werden**

Information Set MCTS

- Information Set MCTS (IS-MCTS) versucht diese Probleme zu lösen
  - *Peter I. Cowling, Edward J. Powley, and Daniel Whitehouse: Information Set Monte Carlo Tree Search, 2012. In: IEEE Transactions on Computational Intelligence and AI in Games. Vol 4, 2, 2012.*
- Statt Spielzustände (= eigene Hand) werden an den Knoten des Suchbaums die eigene Hand und alle möglichen Hände des Gegners gespeichert
  - Dies wird im Verfahren Information Set genannt
- Eine Handlung kann ausgeführt werden, wenn es im aktuellen Information Set eine (oder mehrere) Welt(en) gibt, in der die Handlung ausgeführt werden kann
- Basierend auf dieser Grundidee werden 3 Algorithmen vorgeschlagen
  - Details im Selbststudium

Zusammenfassung

- Min-Max vs. MCTS (siehe auch folgende Folie)
- Grundprinzip als Abfolge von vier Schritten / Datenstruktur
  - Selection mittels UCT
  - Expansion
  - Simulation (“playout”)
  - Backpropagation
- Anwendung auf Würfel- und Kartenspiele
  - Z.B. Determinisierung

- MCTS ist eine Familie neuerer Algorithmen die ab ca. 2006 intensiver untersucht wurden
  - Zum Teil (vielleicht nur dem Dozenten) nicht ganz klar unter welchen Bedingungen MCTS in welcher Variante gut funktioniert

Wann MCTS, wann MinMax

- Zurück zum deterministischen Fall ...
  - Gute Heuristik zur Bewertung von Spielzuständen
    - Spricht für Min-Max
  - Hoher Branching Faktor
    - Spricht für MCTS
  - Gute Heuristik zur Auswahl sinnvoller Handlungen
    - Spricht für MCTS mit Heavy Playout (aber eventuell auch für effizientes Alpha/Beta Pruning)
  - Anwendungsbeispiel: Bohnenspiel
    - Vergleich der Schatzkammern gute Heuristik zur Bewertung von Zuständen
    - Eher kleiner Branching Faktor
    - Eher keine gute Heuristik zur Auswahl sinnvoller Handlungen
    - Min-Max vermutlich besser ...

Programmierprojekt

- Bestanden, wenn Referenz-KI besiegt wird als roter und blauer Spieler
  - Referenz-KI = Min-Max bis Suchtiefe 4 mit einfacher Heuristik
  - Implementierung des Online-Interface
  - REST-Interface siehe Beispielagent

- Einsendung der KI (ausführbarer Code) mit kurzer Dokumentation als Abgabe via ILIAS bis Dienstag 26.10.10:00 Uhr

- Vorab Online Test zu den Zeiten, die im Forum genannt werden!

Bohnen-WM

- Freiwillige Teilnahme!
- Vorherige Anmeldung mit Kampfname im Forum
  - Siehe Beitrag
- Findet statt via Zoom am Mittwoch 27.10. anstelle des Tutoriums
  - Achtung: Wir überziehen vermutlich da vile mehr Teilnehmer als sonst!
- Austragung vermutlich per K.O. System
  - Setzung wird zu Beginn gelost, Ausspielung per Online Interface
  - Jeweils Hin und Rückspiel, Punktesummen entscheiden, bei Punktegleichstand wird gelost
  - 3 Sekunden pro Zug nicht überschreiten, besser 2.5 Sekunden anpeilen

Ablauf im Überblick

12.10. Vorlesung MCTS

19.10. Keine Vorlesung

26.10.Vorlesung Constraints (CSP)

13.10. Tutorium Besprechung Blatt 5

20.10.Tutorium Besprechung Blatt 6

27.10. Bohnen-WM

Blatt 6 lösen

Zwei Wochen Zeit für Entwickeln und Testen der Bohnen-KI

Ausblick

- Vorlesungstermin übernächste Woche:
  - Constraint Satisfaction Problems (CSPs) als eine spezielle Klasse von Suchproblemen mit speziellen Suchverfahren

- Danach geht es dann weiter mit den Themen
  - Logik
  - Planen
  - Machine Learning

Bohnen-KI

Mindestens (!) zehn Stunden einplanen

- Pro MCTS
  - Sollte (theoretisch) überlegen sein
  - Kann Zeitvorgaben genau ausnutzen

- Pro Klassischer Min-Max Suchbaum
  - Einfacher zu implementieren
  - Zum Beispiel Code aus Wikipedia übernehmen
  - Gute und einfache Heursitik
  - Branchingfaktor relativ klein

Fragen

Monte Carlo

Tree