

MiNI-Player – podsumowanie dotychczasowych badań

Maciej Świechowski
promotor: prof. dr hab. Jacek Mańdziuk

O czym opowiem

- Wprowadzenie – motywacja
- Monte-Carlo Tree Search i UCT
- Strategie gry
- Mechanizm oceny i wyboru strategii
- Mechanizm wyboru ruchu podczas gry
- Środowisko testowe
- Wyniki
- Wnioski, plany i oczekiwania

O czym nie opowiem

- Nie będzie elementarnego wprowadzenia do GGP
- Język reguł: GDL
- Interpreter reguł – część MiNI-Player
- Parallelizacja
- Testowane i odrzucone podejścia

Czym jest MiNI-Player

- Agent GGP; program grający w „dowolne” gry mieszczące się w standardzie GGP i GDL-I.
 - skończone i deterministyczne
- Brał udział w konkursie **GGP Competition 2012**
 - wersja z konkursu jest głównym tematem prezentacji

Trendy – zwycięzcy mistrzostw

2005: Cluneplayer

- uogólnione przeszukiwanie drzewa typu min-max
- funkcja ewaluacyjna: wypłata, kontrola, mobilność

2006: FluxPlayer

- wykrywanie struktur semantycznych w opisie gry
 - plansze, kamienie, liczniki, relacje porządku
- logika rozmyta – stopień spełnienia reguł *goal* i *terminal*
- funkcja ewaluacyjna; zmodyfikowany IDDFS

Trendy – zwycięzcy mistrzostw

2007, 2008, 2012: CadiaPlayer

- Podejście czysto symulacyjne: „Knowledge-Free”
- Symulacje Monte-Carlo i algorytm UCT
- Heurystyka historyczna
- Duży nacisk na statystyczną optymalizację procesu MCTS
- Kontrola symulacji: FAST, MAST, TO-MAST, RAVE i inne
- Z czasem wiele prostych dodatków na zasadzie zgadywania i weryfikacji hipotezy

Trendy – zwycięzcy mistrzostw

2009, 2010: Ary

- Monte-Carlo i UCT
- Podejście podobne do CadiaPlayer; prawdopodobnie mniej rozbudowane
- Nested Monte-Carlo do gier jednoosobowych
- Duży wysiłek badawczy w zakresie technik zrównoleglenia

Trendy – zwycięzcy mistrzostw

2011: TurboTurtle

- „Simulation-Based” – wg prezentacji autora o GGP
- brak publikacji – nie wiadomo wiele o tym graczu

Trendy – zwycięzcy mistrzostw

2011: TurboTurtle

- „Simulation-Based” – wg prezentacji autora o GGP
- brak publikacji – nie wiadomo wiele o tym graczu

2013: ??? 😊

**„AI systems are dumb because
AI researchers are too clever.”**

JACQUES PITRAT (1968)

Motywacja


- Usprawnienie losowych symulacji poprzez wprowadzenie wiedzy
- Próba bezpiecznej aplikacji wiedzy
MCTS vs Min-Max/Alfa-Beta/MTD(f)
- Próba dalszego udoskonalenia podejścia, które uznawane jest za *state-of-the-art* w General Game Playing

MCTS/UCT vs MinMax/ $\alpha\beta$ /MTD(f)

- Łatwe zrównoleglenie
- Podejście skalowalne
- Można w każdej chwili przerwać
- Symulacje mogą „robić błędy”
- W podstawowej wersji wystarczy logika gry (knowledge-free)
- Potrzebuje silnej i bezbłędnej funkcji oceny stanu
- W przypadku posiadania takiej funkcji, ma przewagę nad MCTS

POJĘCIA BAZOWE

Drzewo gry



[źródło: <http://www.ocf.berkeley.edu/~yosenl>]

Drzewo gry

Dowolna liczba graczy

- **Wierzchołek w drzewie:** stan w grze
- **Krawędź (A,B):** wektor akcji każdego z graczy (akcja połączona: *joint move*) powodująca zmianę stanu z A do B
np. (noop (mark 1 1 x))

Można nie powtarzać tych samych stanów, do których istnieje wiele ścieżek => graf skierowany

Monte-Carlo Tree Search (MCTS)

Wykonujemy losowe symulacje i przechowujemy statystyki w węzłach:

- sumaryczny wynik gry każdego z graczy
- liczbę odwiedzin w węźle
- średni wynik – wyliczany na podstawie powyższych dwóch

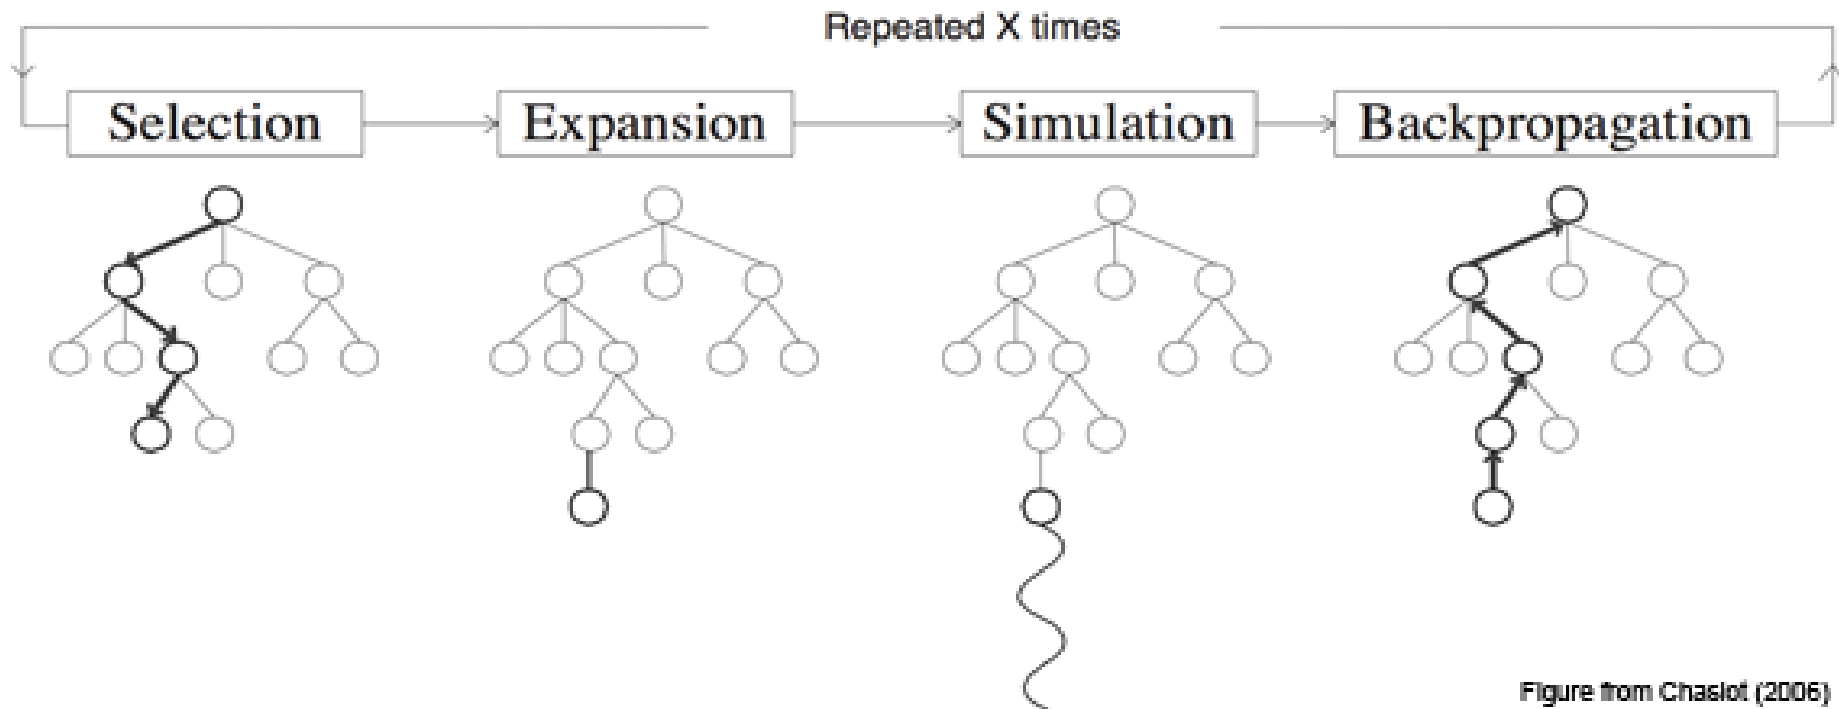
Podejście typu knowledge-free.

Wystarczy zaimplementować mechanikę gry

Monte-Carlo Tree Search (MCTS)

- **Selekcja:** w każdym węźle rozpoczynając od wierzchołka wybieramy najlepszego potomka do kontynuacji przeszukiwania
- **Rozwinięcie:** gdy jesteśmy w liście to tworzymy nowy węzeł
- **Symulacja:** gramy losowo aż do osiągnięcia stanu terminalnego
- **Propagacja wsteczna:** uaktualniamy statystyki – średni wynik oraz liczbę odwiedzin w każdym węźle na ścieżce, którą wybraliśmy

Monte-Carlo Tree Search (MCTS)



UCT *(Upper Confidence Bounds Applied For Trees)*

- Modyfikacja algorytmu **UCB**
[k-armed/multiarmed bandit problem]



Bandyta: Stała, nieznana dystrybuanta wypłat

Cel: maksymalizacja zysku

$$a^* = \arg \max_{a \in A(s)} \left\{ Q(s, a) + C \sqrt{\frac{\ln N(s)}{N(s, a)}} \right\}$$

Dla danej roli (gracza):

a – akcja

s – bieżący stan

Q(s,a) – uśredniony osiągnięty wynik gry przy wykonaniu akcji **a** w stanie **s**

N(s) – liczba dotychczasowych odwiedzin stanu **s**

N(s,a) – liczba dotychczasowych wyborów akcji **a** w stanie **s**

Zasada balansu między **eksploracją** nowych ścieżek a **wykorzystaniem** najlepszych do tej pory.

klasyczny problem **exploration** vs **exploitation**

Celem jest ukierunkowanie symulacji na najbardziej obiecujące fragmenty w drzewie.

[L. Kocsis and C. Szepesvari, 2006]

CrazyStone

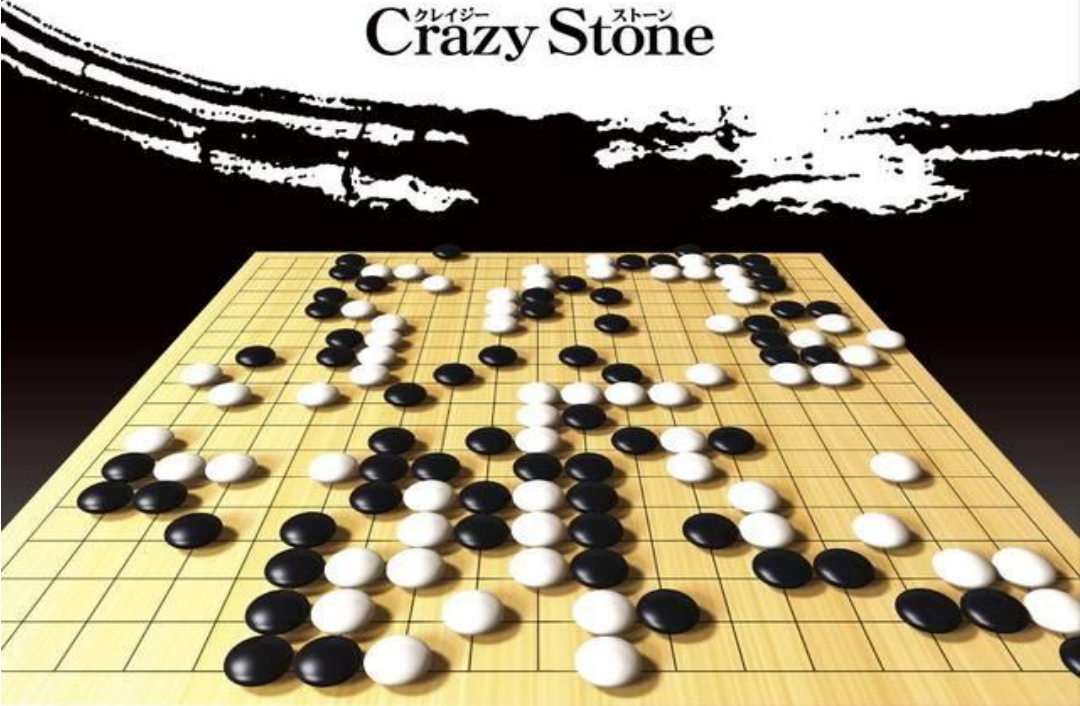
2006

Komercyjne
zastosowanie UCT

前作(最強の囲碁 2011)よりさらに一子、強くなりました。

最強の囲碁 2012

クレイジーストーン
Crazy Stone



前作との自己対戦勝率 **78%**
(※最高レベルの棋力は「五段」に迫る強さになります)

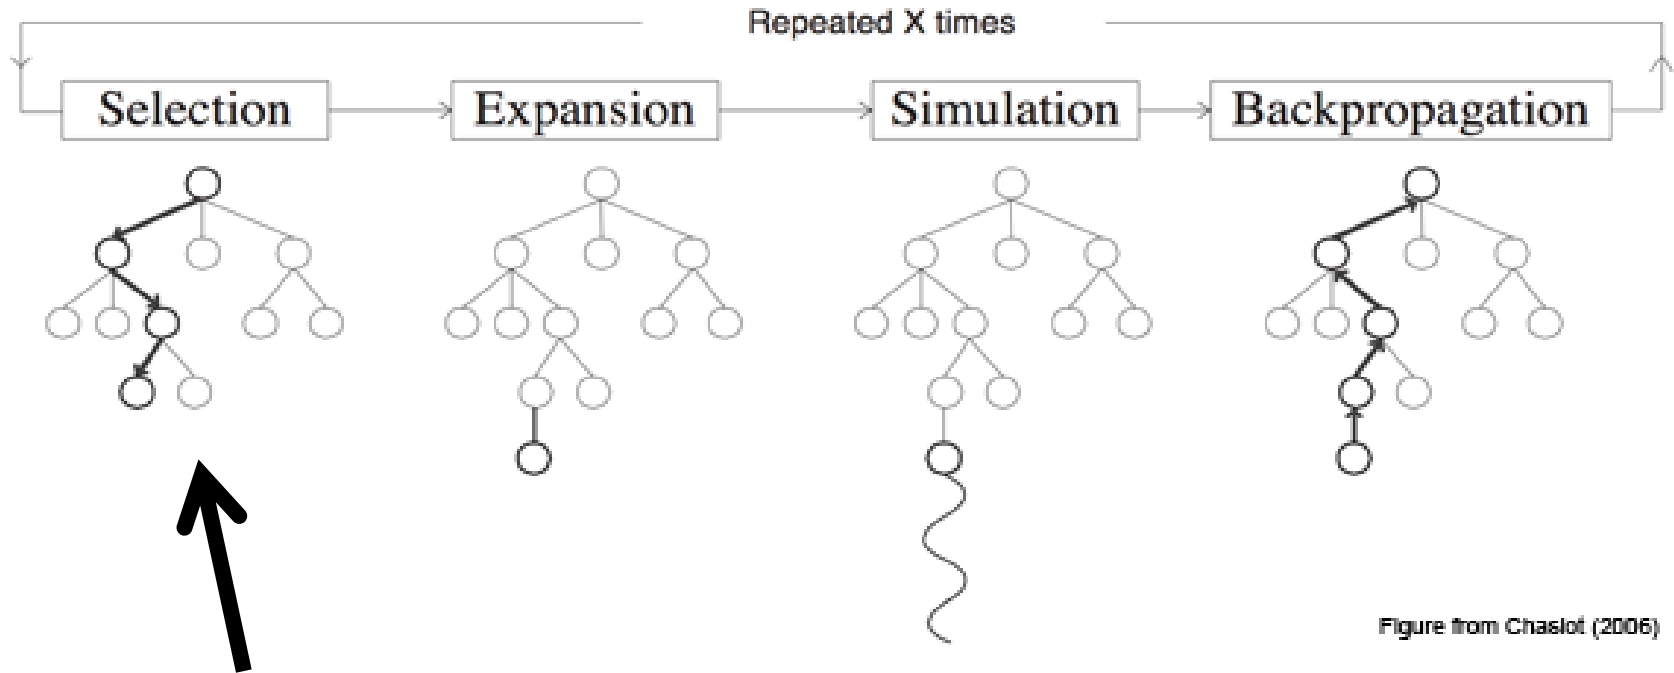
さらに強く、そして速く…。
この一年間で一層の進化を遂げた思考エンジン、「Crazy Stone」。

UNBALANCE.

for Windows®XP/Vista/Windows 7
◎バンドネットの無料チケット付き◎

Zastosowanie UCT w MiNI-Player

- Optymalizacja fazy **selekcji**
- Dla każdego z graczy – stosowane osobne UCT



Warunki stawiane symulacji w Go

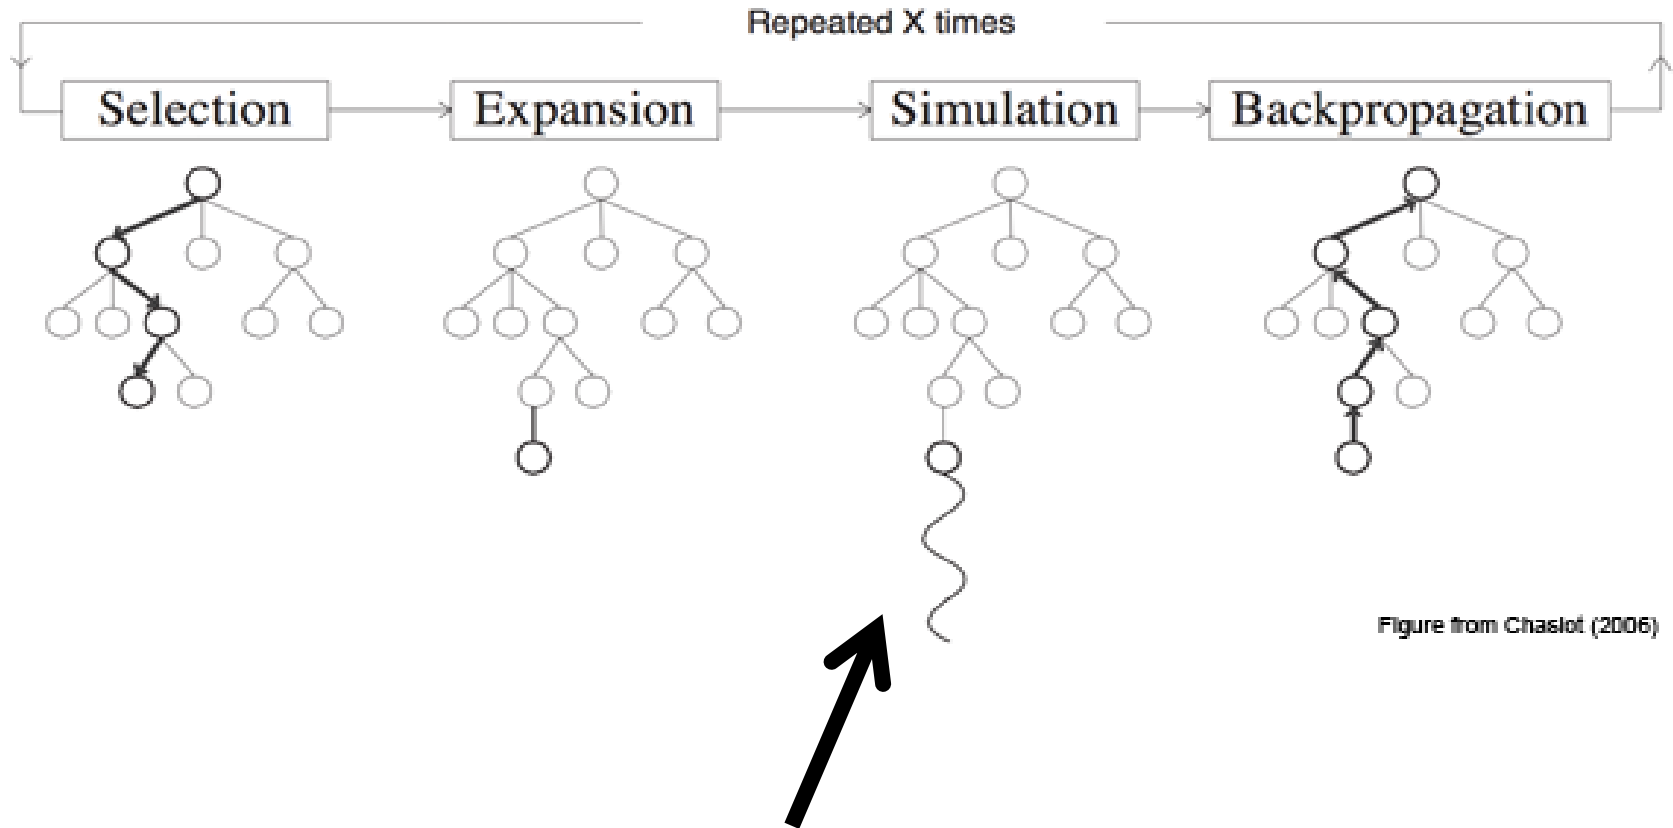
Ostatnie badania w Go, grze której rozwiązania zainspirowały twórców najsilniejszych programów GGP wskazują, że symulacje MCTS powinny:

- **Wybierać silne akcje, które zagrałby gracz**
- **Być różnorodne**

STRATEGIE SYMULACJI

Zastosowanie strategii w MiNI-Player

- Optymalizacja fazy **symulacji**



Schemat symulacji w GGP

dopóki(krok < MAX_STEP)

1. Wyznacz legalne akcje

[legal]

2. Dla każdej roli $i=0\dots N$

[does]

 move[i] = wybierz akcję

 wykonaj(move[i])

3. Wyznacz, a następnie uaktualnij stan gry

[next]

4. Sprawdź czy stan jest terminalny:

[terminal]

 TAK: pobierz wyniki i zakończ symulację

[goal]

 NIE: wróć do punktu 1.

Dostępne strategie

W turniejowej wersji MiNI-Player:

- Random
- AGE (Approximate Goal Evaluation)
- HH (History Heuristic)
- M (Mobility)
- E (Exploration)
- SSC (Statistical Symbol Counting)

Kandydaci do przetestowania:

- M2 (Mobility 2-ply) i inne wersje 2-ply
- Sc (Score)

Random

- Strategia losowa: wszystkie akcje tak samo prawdopodobne
- Niezwykle ważna, bo:
 - Zwiększa różnorodność przeszukiwania – nie trzyma się konkretnej ścieżki
 - Wydajna obliczeniowo, co pozytywnie wpływa na ilość wykonywanych symulacji

(marginalnie szybsze byłoby tylko zawsze wybieranie akcji o stałym indeksie)

- Przybliżony stopień spełnienia warunku *goal*
wybierany jest zbiór reguł *goal* z najwyższą wypłatą dla każdego gracza
- Podobna idea do FluxPlayer, lecz inne wykonanie.

AGE – pojęcie wstępne

- Relacja: **knight_move** (zbiór wszystkich faktów i reguł)

- Reguły:

```
(<= (knight_move ?piece ?u ?v ?x ?y ?owner)
  (piece_owner_type ?piece ?owner knight)
  (adjacent_two ?v ?y)
  (adjacent ?u ?x))
```

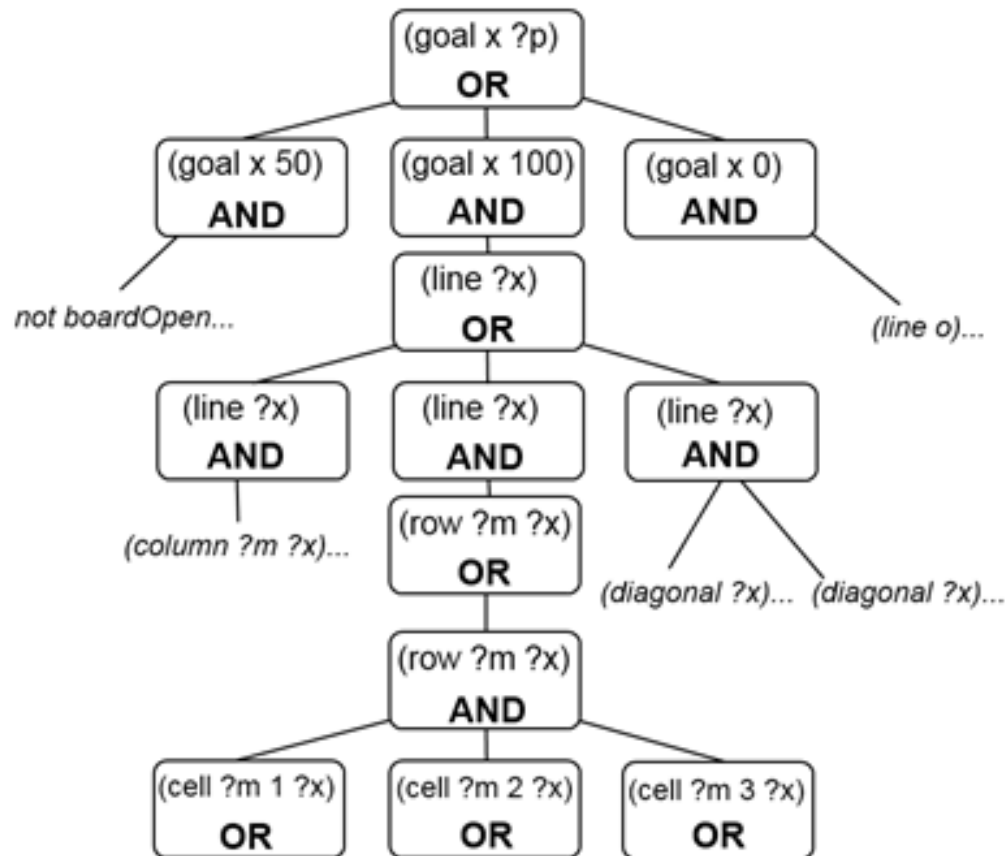
```
(<= (knight_move ?piece ?u ?v ?x ?y ?owner)
  (piece_owner_type ?piece ?owner knight)
  (adjacent_two ?u ?x)
  (adjacent ?v ?y))
```

- Warunek \Leftrightarrow Zapytanie \Leftrightarrow Wywołanie relacji:

```
(adjacent_two ?u ?x)
```

```
(knight_move ?piece c 4 ?x ?y white)
```

Reprezentacja kaŹdej reguły jako drzewa OR-AND

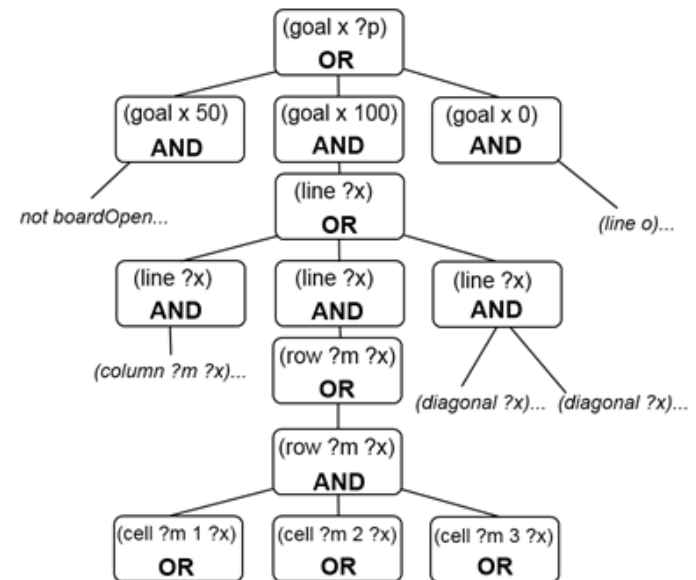


Reprezentacja każdej reguły jako drzewa OR-AND

- **OR:** reprezentuje kontener na wszystkie zdefiniowane reguły dla danej relacji np. goal, legal, cell

(czyli de facto zapytanie o fakty danego typu – bo pytając nie specyfikujemy konkretnej instancji reguły)

- **AND:** reprezentuje konkretną instancję reguły



Metoda obliczania AGE jest zdefiniowana rekurencyjnie na drzewie.

- rozpoczyna się w korzeniu
- obliczane i propagowane wstecz są 2 wartości: **AgVal** i **TbVal** (**A**pproximate**G**oal**V**alue i **T**ie**B**reaker**V**alue)

Możliwa dzięki własnej implementacji interpretera reguł.

AGE – węzły typu AND

$i=1\dots N$ – węzły OR będące dziećmi bieżącego węzła AND

$$AgVal = \frac{1}{N} \sum_{i=1}^N AgVal_i$$

$$TbVal = \frac{1}{N} \sum_{i=1}^N TbVal_i$$

Jeżeli warunek reprezentowany przez OR posiada negację, to wartości wchodzą do sumy jako $1 - AgVal_i$ oraz $1 - TbVal_i$

AGE – węzły typu OR

1. Liść

$AgVal = 1$, jeśli reguła jest spełniona.

$AgVal = 0$, jeśli reguła nie zachodzi

Innymi słowy, pytamy czy zachodzi co najmniej jedna realizacja zmiennych dla zapytania reprezentowanego przez węzeł.

2. Węzeł wewnętrzny:

$$AgVal = \max_{i=1\dots N} AgVal_i$$

$$TbVal = \frac{1}{N} \sum_{i=1}^N TbVal_i$$

Heurystyka Historyczna

Uniwersalna metoda stosowana w AI w grach od 1989
[Schaeffer]

Ideą jest, by przenieść informację uzyskaną z wykonanych akcji wcześniej w procesie symulacji do nowej sytuacji, gdy akcja jest znów możliwa do wykonania.

W GGP większość programów stosuje HH, aby zwiększyć prawdopodobieństwo wybrania akcji dobrych niezależnie od stanu podczas symulacji Monte-Carlo.

Heurystyka Historyczna w MiNI-Player

- Globalny słownik akcji dla każdego z graczy
- Akcje wybierane podczas symulacji pozostałymi strategiami są zapamiętywane
- Po zakończeniu symulacji uaktualniane są średnie wyniki

- Podczas symulacji z użyciem HH w każdym kroku z prawdopodobieństwem ε wybierany jest najlepiej oceniony ruch z aktualnie legalnych
(w przeciwnym przypadku lub gdy takiego nie ma – losowy)

Mobility

Liczba dostępnych akcji względem pozostałych graczy

- zwykle im więcej tym lepiej
(*więcej możliwości, więcej figur w grach planszowych*)

- Niech M_i oznacza liczbę akcji dostępnych dla i -tego gracza
- Niech $i=0$ oznacza rolę przypisaną MiNI-Playerowi

Wybieramy stan, w którym maximum osiąga wyrażenie:

$$M_0 + \sum_{i=1}^{N-1} (M_0 - M_i)$$

Exploration

Idea tej strategii polega na odwiedzaniu nowych stanów, które w największym stopniu różnią się od ostatnio odwiedzanych.

Exploration

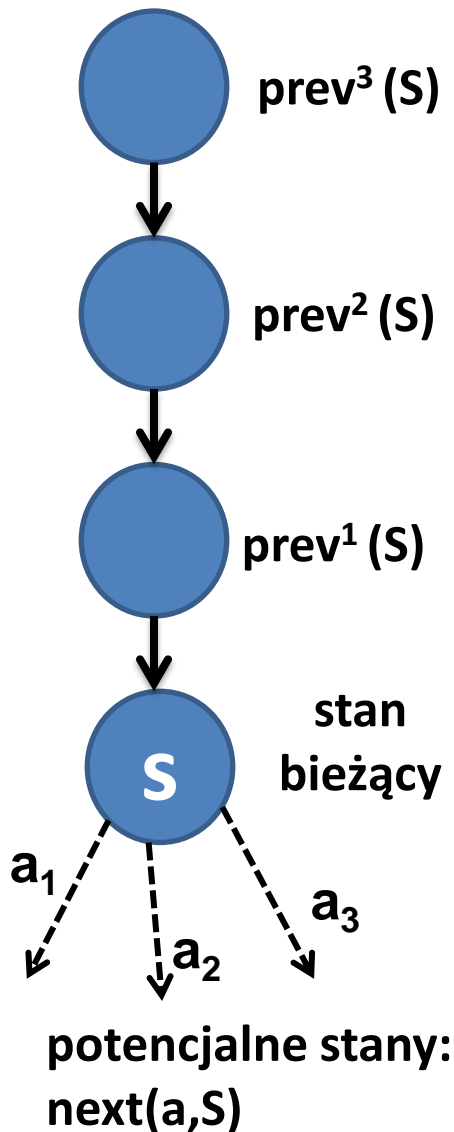
Idea tej strategii polega na odwiedzaniu nowych stanów, które w największym stopniu różnią się od ostatnio odwiedzanych.

Różnica między stanem B i A:

$$\text{diff}(B,A) = B - A \quad |\{f: f \in B \wedge f \notin A\}|$$

- Liczność zbioru faktów (termów GDL), które należą do B oraz nie należą do A

Exploration



Dla każdej legalnej akcji a_i w bieżącym stanie S wyznacz stan następny $S'_i = \text{next}(a_i, S)$

Dla każdego i wyznacz najbardziej podobny stan z ostatnich N :

$$\min_i d_i = \min_{j=1..N} \text{diff}[S'_i, \text{prev}^j(S'_i)]$$

Wybierz akcję, której najbardziej podobny stan jest od niej maksymalnie różny:

$$a_i := \arg \max_i \left(\min_i d_i \right)$$

Statistical Symbol Counting

Idea zaczerpnięta z wcześniej testowanego podejścia do budowania funkcji ewaluacyjnej.

- **wzięty podzbiór (prostsza część)**

Strategia ma dwa fazy:

- **uczącą**: w czasie START CLOCK
- **grającą**: po zakończeniu fazy uczącej

Faza ucząca – wykorzystuje symulacje przeprowadzane przez pozostałe strategie, aby zbierać informacje

Statistical Symbol Counting

Podczas symulacji uczących:

Dla każdej **relacji** zdefiniowanej w GDL obecnej w stanie gry:

- wyznaczana jest liczność faktów (realizacji)

Dla każdej pary: **indeks** na liście argumentów realizacji (nr kolumny) oraz **symbol**:

- wyznaczana jest liczba symboli

Wszystkie liczności uśredniane są dla symulacji.

(vs liczność z końcówki, vs średnia ważona długością symulacji)

Statistical Symbol Counting

```
[cell 1 1 x]
[cell 1 2 b]
[cell 1 3 x]
[cell 2 1 b]
[cell 2 2 o]
[cell 2 3 b]
[cell 3 1 b]
[cell 3 2 b]
[cell 3 3 b]
```

Quantity("cell") = 9

Quantity("cell", 1, "1") = 3

Quantity("cell", 1, "2") = 3

Quantity("cell", 1, "3") = 3

Quantity("cell", 2, "1") = 3

Quantity("cell", 2, "2") = 3

Quantity("cell", 2, "3") = 3

Quantity("cell", 3, "x") = 2

Quantity("cell", 3, "o") = 1

Quantity("cell", 3, "b") = 6

Optymalizacje odcinające po pewnym momencie niektóre kolumny.


Statistical Symbol Counting

Średnia wartość danej cechy może zostać dodana do jednego z dwóch kubeków na podstawie wyniku zakończonej symulacji:

$i = 0$ – indeks roli przypisanej do MiNI-Player

N – liczba graczy

$$R = goal_0 - \max_{i=1..N}(goal_i)$$



Statistical Symbol Counting

Średnie wartości są dalej uśredniane oddzielnie dla całej przestrzeni kubeków:

- Gier wygranych
- Gier przegranych

Cesze przypisywana jest waga:

$$w = AVG_{wins} - AVG_{losses}$$

Odrzucane są cechy z wagami $|w| < 0.0001$

Tworzona jest funkcja oceny stanu jako kombinacja liniowa:

liczność cechy * waga cechy

Dobór parametrów

Nawet wybrana strategia do przeprowadzenia symulacji ma pewne prawdopodobieństwo P wykonania akcji zgodnie ze swoją formułą.

- aby zapewnić różnorodność przebiegów

P	AGE Checkers	SSC Chess	M Othello	E Farming Quandries	HH Connect-4
0.20	59.17	50.00	54.33	54.83	54.67
0.40	66.00	51.00	55.50	56.50	55.83
0.50	65.67	51.33	68.17	58.17	59.33
0.60	70.67	51.00	73.83	59.50	59.00
0.65	79.17	50.83	73.67	60.67	57.33
0.70	76.33	51.33	81.33	61.17	66.67
0.75	79.33	49.50	83.67	61.67	62.92
0.80	75.83	53.17	81.17	62.17	59.17
0.85	72.67	54.17	85.17	58.33	54.83
0.90	69.33	54.64	79.17	42.50	50.67
1.00	55.67	55.00	68.17	34.83	44.17
95% Conf.	±4.46	±9.07	±3.90	±5.10	±5.13

Potencjalne strategie

- Przeszukiwanie na 2 kroki do przodu
- Wykrycie liczników – faktów, które zawierają w danym momencie jedną wartość dla każdego z graczy
(maksymalizacja/minimalizacja tych wartości)
- Wykrywanie planszy?
- N-grams? Szeregi akcji do wykonania w przypadku gier o niewielkiej interakcji między graczami?
- Obliczanie odległości między faktami – minimalizacja/maksymalizacja/koncentracja

sugestie? 😊

Mechanizm wyboru strategii

Testowane rozwiązania:

1. Proporcjonalnie do średniego wyniku
2. Proporcjonalnie do kwadratu średniego wyniku
3. Statyczna alokacja na N symulacji bazująca na liście rankingowej strategii
4. Algorytm UCB

1. Proporcjonalnie do Q

- Weźmy dwie strategie S_1 oraz S_2 o ocenach $Q_1 = 0.6$, $Q_2 = 0.5$

Przydzielając ilości symulacji N dla strategii proporcjonalnie do Q , otrzymujemy:

$$N_1 = 120$$

$$N_2 = 100$$

po 220 symulacjach!

2. Proporcjonalnie do Q^2

Planujemy kolejkę strategii przydzielanych do symulacji:

1. Znajdujemy $d = \min(Q_i)$ – „najśłabszą” strategię
2. Obliczamy znormalizowane wartości średnie dla każdej strategii:

$$AVG_i = \frac{Q_i}{d}$$

3. Przydzielamy i-tej strategii ilość symulacji N_i :

$$N_i = \lfloor R_i \rfloor, \quad R_i = (AVG_i + OF_i)^2$$

4. Obliczamy przepiętnienie OF w bieżącym kroku:

$$OF_i = R_i - \lfloor R_i \rfloor$$

2. Proporcjonalnie do Q^2

Planujemy $\sum N_i$ następných symulacji

- równomiernie przeplatając
- startując od najlepiej ocenionych strategii

Przykład:

$$N_1 = 4, N_2 = 3, N_3 = 1$$

Wynik => plan symulacyjny:

[S1, S2, S1, S2, S3, S1, S2, S1]

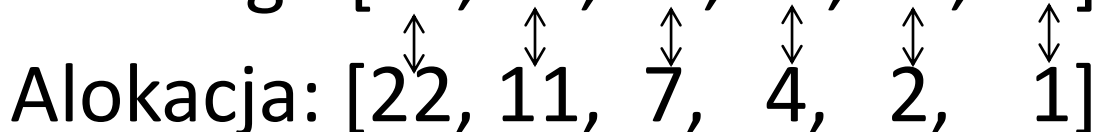
3. Statyczna alokacja

- Budujemy listę rankingową strategii sortując po średnim wyniku Q_i
- Przydzielamy z góry ustaloną liczbę symulacji w zależności od zajmowanego miejsca na liście

Przykład (dla MiNI-Player):

Ranking: [S3, S2, S6, S1, S4, S5]

Alokacja: [22, 11, 7, 4, 2, 1]



4. UCB

- Tu nie planujemy z góry symulacji, tylko decyzje podejmujemy w każdym kroku bazując na formule:

$$S^* = \mathit{arg} \max_{i=1\dots6} \left\{ Q_i + C \sqrt{\frac{\ln n}{T(S_i, n)}} \right\}$$

S^* - wybrana strategia

n - liczba wszystkich symulacji od początku

$T(S_i, n)$ – liczba wyborów strategii S_i wśród n symulacji

C – współczynnik eksploracji; $C = 5$ (wersja na mistrzostwa)

Porównanie mechanizmów selekcji

- AVG (Q^2)
 - zbyt słabe wyeksponowanie najlepszych strategii
- UCB
 - sprawdzona metoda, uzasadniona statystycznie
 - ryzyko zbytnej dominacji jednej strategii
- Static
 - w praktyce okazuje się bardzo dobra
 - nieoptymalna w ekstremalnych przypadkach:
istnienia ewidentnie złej lub ewidentnie jedynej
dobrej strategii


Porównanie mechanizmów selekcji

Koszt obliczeniowy:


$$\text{Static} > \text{AVG} (Q^2) > \text{UCB}$$

w praktyce pomijalny w stosunku do czasów symulacji

Alokacja symulacji dla najlepszej strategii



Alokacja symulacji dla najgorszej strategii



Mechanizm wyboru akcji

Akcja – składowa wektora w krawędzi wychodzącej z aktualnego korzenia

Wersja klasyczna przy korzystaniu z UCT:

- Wybierz akcję prowadzącą do potomka o **najlepszym średnim wyniku Q**
- Wybierz akcję najczęściej symulowaną

(w wyjątkowych sytuacjach oba przypadki nie są tożsame)

Mechanizm wyboru akcji

- MiNI-Player korzysta ze zmodyfikowanej formuły **EQ**, która wykorzystuje dane z 2 poziomów w drzewie
- Wybrany zostaje potomek **Root.Child[i]** o największej wartości **EQ**

Obliczanie EQ

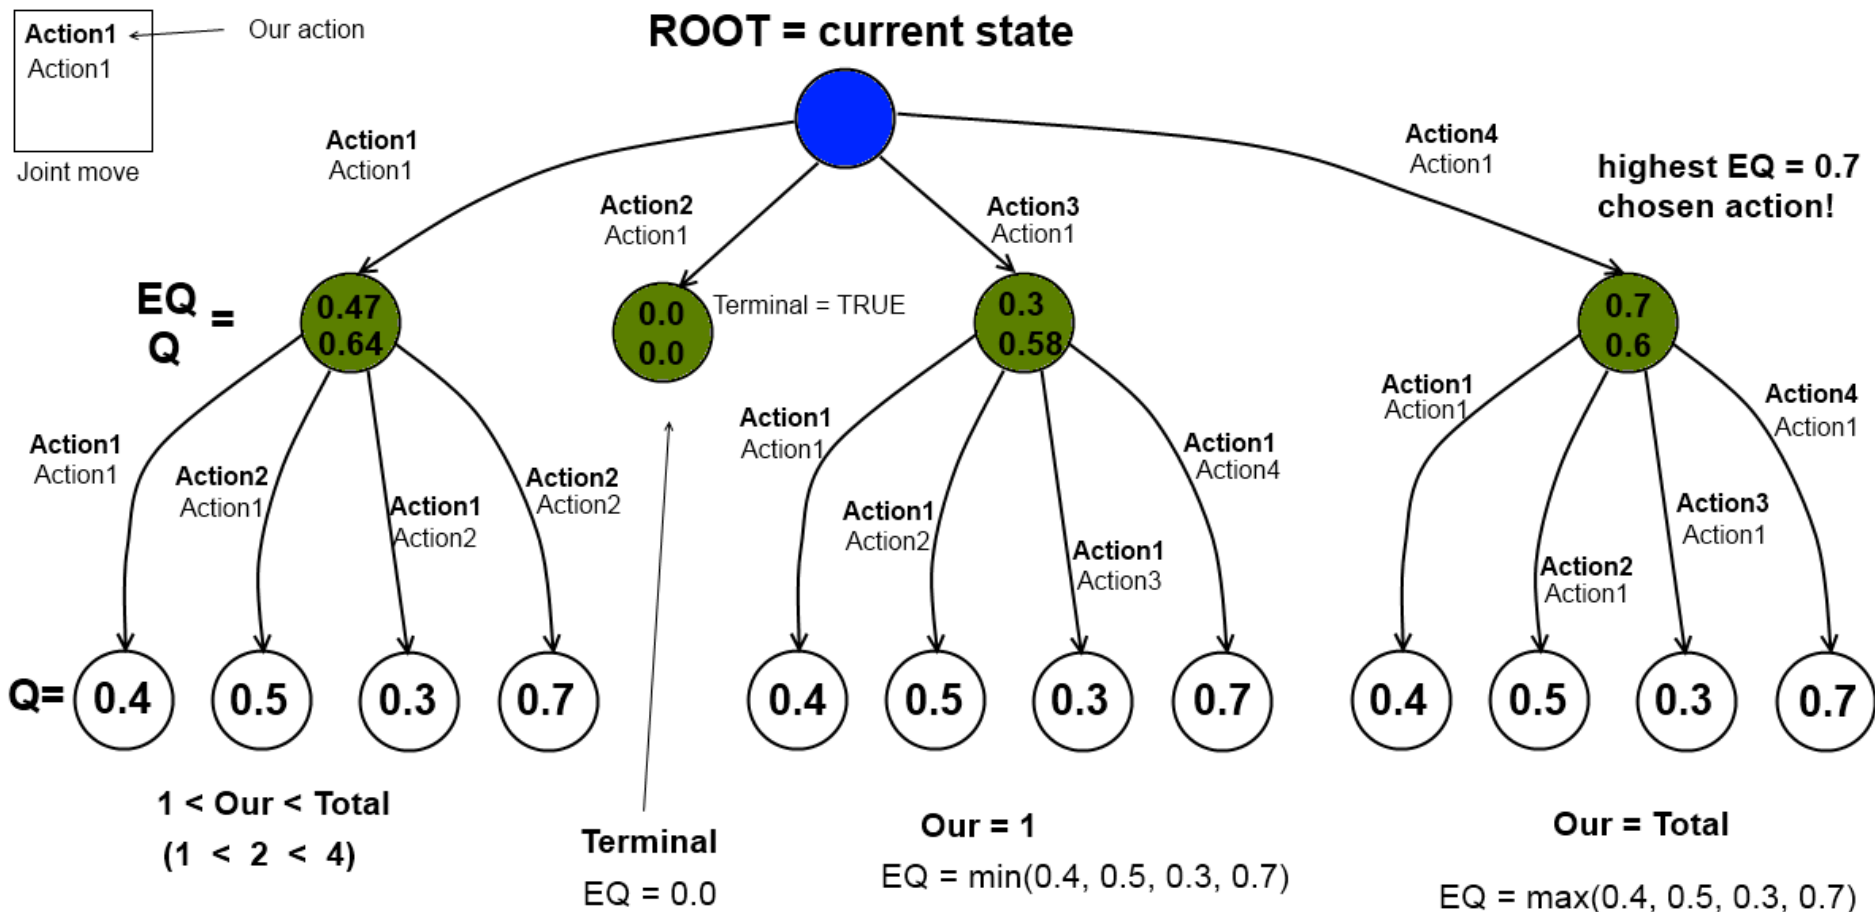
Our – liczba unikalnych akcji naszego gracza

Total – liczba wszystkich dostępnych akcji łączonych (joint moves)

Iterujemy po węzłach wychodzących z korzenia:

Warunek w węźle	EQ
Stan terminalny = TRUE	$EQ = node.Q \quad (1.01 * node.Q)$
Our = 1	$EQ = \min_{i=1\dots N} (node.Child[i].Q)$
$1 < Our < Total$	$EQ = \frac{(\min_{i=1\dots N} (node.Child[i].Q) + node.Q)}{2}$
Our = Total	$EQ = \max_{i=1\dots N} (node.Child[i].Q)$

Mechanizm wyboru akcji



$EQ = 0.5 * (0.64 + \min(0.4, 0.5, 0.3, 0.7))$

Tabele transpozycji

- Stosowane w grach, aby nie duplikować w drzewie powtarzających się stanów
- Procedura znalezienia identycznego stanu (porównywania stanów) musi być bardzo wydajna
 - sprawdzanie po każdym napisie GDL nie wchodzi w grę, zwłaszcza, że mogą być w dowolnej kolejności
 - Pesymistyczna złożoność: $N * R * C$
 - N: liczba węzłów w drzewie
 - R: liczba relacji składających się na stan
 - C: średnia liczba faktów występującej dla danej relacji

Tabele transpozycji

- W grach znanych z góry stosuje się bardzo wydajne reprezentacje stanów np. Zobrist Hashing/Keys
- Przede wszystkim znana jest natura gier i wymiary poszczególnych elementów

Tabele transpozycji w MiNI-Player

- Funkcja hashująca dla realizacji GDL efektywną w obrębie swojej relacji:

cell	a	2	b	→	17
cell	a	3	b	→	20
cell	a	4	wr	→	35
cell	b	2	b	→	53
cell	b	3	wn	→	14
cell	g	8	br	→	34

- Funkcja hashująca dla całej relacji – suma + zoptymalizowana metoda EqualTo do radzenia sobie z kolizjami

Tabele transpozycji w MiNI-Player

Klasyfikacja stanów, ze względu na pewne cechy celem przyspieszenia

- Sumaryczna liczba legalnych akcji
- Sumaryczna ilość realizacji
- Ilość niepustych relacji
(w sensie liczności zbioru realizacji)
- Ilość realizacji dla każdej z relacji
(relacje znane są apriori bezpośrednio z reguł)

Tabele transpozycji w MiNI-Player

Nie ma modyfikacji struktury drzewa.

- Przy dodaniu nowego węzła sprawdzane jest istnienie węzłów transponowanych
- W fazie propagacji wyniku – wynik jest tak samo propagowany na węzły transponowane

Wciąż można przechodzić w drzewie wieloma ścieżkami do tego samego stanu, ale podbicie liczby odwiedzin w połączeniu z algorytmem UCT minimalizuje wynikające z tego problemy.

WYNIKI EKSPERYMENTALNE

Gry z mistrzostw 2012

- Connect-4
- Cephalopod Micro
- Free for All 2P
- Pentago
- 9 Board Tic-Tac-Toe
- Connect-4 Suicide
- Checkers
- Farming Quandries
- Pilgrimage

Wyniki vs CadiaPlayer

5-4 w grach

Game	Clock [s]		MINI vs. Cadia	GGP 2012 Result
Connect4	40	15	41.67 [5.35]	Loss (error)
Cephalopod Micro	60	20	40.00 [5.84]	Loss
Free for all 2P	45	15	63.33 [5.14]	Win
Pentago	45	15	29.33 [5.43]	Loss
9 Board Tic-Tac-Toe	45	15	70.67 [5.16]	Win
Connect4 Suicide	45	15	53.33 [5.26]	Win
Checkers	60	20	54.33 [5.88]	Win
Farming Quandries	90	30	68.33 [4.21]	Loss
Pilgrimage	90	30	42.67 [4.32]	Loss
Average			51.40 [5.18]	

Wyniki gracza bez strategii i EQ

Gracz na bazie MINI-Player, tylko z heurystyką historyczną (bez innych strategii symulacji)

Game	MINI vs. MINI-C	Cadia vs. MINI-C
Connect4	61.33 [5.69]	59.67 [5.54]
Cephalopod Micro	59.33 [5.86]	73.33 [5.27]
Free for all 2P	75.33 [4.86]	65.67 [5.11]
Pentago	40.00 [5.84]	55.33 [5.93]
9 Board Tic-Tac-Toe	66.30 [5.42]	50.00 [5.76]
Connect4 Suicide	51.33 [5.72]	43.33 [5.50]
Checkers	79.33 [4.83]	69.33 [5.32]
Farming Quandries	66.67 [5.36]	59.67 [4.90]
Piligrimage	39.33 [5.40]	62.83 [5.39]
Average	59.88 [5.44]	59.91 [5.42]

Wyniki dla gier jednoosobowych

2-1-2 ze średnią na korzyść MiNI-Player

Game	Clock [s]		MINI-Player	CadiaPlayer
Hanoi	30	20	80.70 [0.55]	99.00 [0.52]
Knight Tour	30	20	100.00 [0.00]	100.00 [0.00]
8-Puzzle	30	20	64.80 [4.82]	3.60 [2.10]
Lights Out	30	20	18.50 [4.63]	0.00 [0.00]
Rubik's Cube	30	20	0.00 [0.00]	13.25 [1.17]
Average			52.80 [2.00]	43.17 [0.76]

Siła poszczególnych usprawnień

Game	MINI-EQ vs. Cadia	MINI-STR vs. Cadia
Connect4	54.84 [5.85]	40.00 [5.42]
Cephalopod Micro	36.67 [5.75]	40.00 [5.84]
Free for all 2P	39.81 [5.31]	59.56 [5.39]
Pentago	45.93 [5.94]	31.33 [5.53]
9 Board Tic-Tac-Toe	49.33 [5.72]	66.67 [5.41]
Connect4 Suicide	60.67 [5.40]	51.33 [5.33]
Checkers	24.00 [5.05]	53.67 [5.93]
Farming Quandries	39.33 [4.60]	64.67 [4.54]
Pilgrimage	35.67 [4.09]	40.33 [4.55]
Average	42.91 [5.30]	49.73 [5.33]

Podsumowanie usprawnień

Game	MINI-C	MINI-EQ	MINI-STR	MINI
Connect4	1.00	1.36	0.99	1.03
Cephalopod Micro	1.00	1.38	1.50	1.50
Free for all 2P	1.00	1.16	1.73	1.84
Pentago	1.00	1.03	0.70	0.66
9 Board Tic-Tac-Toe	1.00	0.99	1.33	1.41
Connect4 Suicide	1.00	1.07	0.91	0.92
Checkers	1.00	0.78	1.75	1.77
Farming Quandries	1.00	0.98	1.60	1.69
Pilgrimage	1.00	0.96	1.09	1.15
Average	1.00	1.07	1.24	1.28

Ocena strategii dla poszczególnych gier

Game	R	AGE	M	HH	E	SSC
Connect4	54.6	78.1	55.00	80.6	58.3	54.0
Cephalopod Micro	49.1	34.9	44.3	57.9	34.8	42.6
Free for all 2P	52.4	68.0	58.5	76.2	94.5	84.5
Pentago	48.9	75.7	43.1	47.0	45.4	45.7
9 Board Tic-Tac-Toe	51.3	71.8	49.7	32.0	48.5	46.6
Connect4 Suicide	54.1	51.4	49.0	59.2	45.0	49.6
Checkers	48.8	77.7	64.1	54.7	75.0	78.5
Farming Quandries	1.0	2.5	0.9	1.0	37.2	1.5
Pilgrimage	0.1	0.2	0.3	0.4	0.9	0.2
Average	40.0	51.1	40.5	45.4	48.8	44.8

Gracz korzystający z najlepszej strategii

Game	MINI-1-S vs. MINI-Player
Connect4	52.41 [5.90]
Cephalopod Micro	45.92 [5.94]
Free for all 2P	48.33 [5.56]
Pentago	50.00 [5.96]
9 Board Tic-Tac-Toe	52.96 [5.75]
Connect4 Suicide	40.30 [5.60]
Checkers	57.78 [5.78]
Farming Quandries	58.89 [5.33]
Piligrimage	35.63 [5.33]
Average	49.14 [5.68]

Podsumowanie

- Wprowadzenie strategii symulacji wyraźnie zwiększyło siłę gracza MiNI-Player
- Zmodyfikowana formuła wyboru ruchu EQ wraz ze strategiami również poprawia wyniki

Bez modyfikacji: wyniki vs CadiaPlayer to **1-8**

Z modyfikacjami: wyniki vs CadiaPlayer to **5-4**

Wciąż dużo otwartych pytań i problemów:

- **Modelowanie przeciwników**
- **Jak siła symulacji MCTS wpływa na jakość ostatecznego gracza?**
- **Uwzględnienie strategii przy wyborze ruchu do zagrania?**
 - W zależności od wiedzy o adekwatności strategii
 - W przypadku niedostatecznej liczby symulacji, żeby polegać na średnim wyniku

Wciąż dużo otwartych pytań i problemów:

- **Nowe strategie...**
- **Przyspieszenie symulacji – losowanie tylko podzbioru możliwych następnych stanów przy analizie ruchu przez strategie gry**
- **Podział gry na fazy early-mid-end i stosowanie odrębnych strategii**

Wciąż dużo otwartych pytań i problemów:

- **Monitorowanie wydajności strategii – ile razy „zadziałała” a ile razy każdy ruch miał taką samą ocenę (np. Mobility w Connect-4)**
- **Stosowanie strategii zastępczych do powyższych przypadków**
- **Pogrupowanie strategii w zestawy i połączenie z mechanizmem zrównoleglenia**

Dziękuję za uwagę