

Sztuczna inteligencja w grach

dr inż. Piotr Beling

Warszawa, 29 grudnia 2016

Obszar zainteresowań

Wyznaczanie suboptymalnych decyzji w grach, głównie:


- ▶ dwuosobowych,
- ▶ o stałej sumie wypłat,
- ▶ deterministycznych,
- ▶ skończonych,
- ▶ z doskonałą informacją.

Przykłady:

szachy, warcaby, kółko i krzyżyk, GO



Gra jako acykliczny graf skierowany




wierzchołki = pozycje gry

krawędzie = możliwe ruchy

dla pozycji końcowych (bez następników) określona wypłata graczy

(rysunek pochodzi z *Wikipedii* – Tic-tac-toe-game-tree.svg)


Który ruch wykonać? – wartości minimaksowe pozycji



○ – ruch gracza *Max*

□ – ruch gracza *Min*


Który ruch wykonać? – wartości minimaksowe pozycji



○ – ruch gracza *Max*

□ – ruch gracza *Min*


Który ruch wykonać? – wartości minimaksowe pozycji



○ – ruch gracza *Max*

□ – ruch gracza *Min*


Który ruch wykonać? – wartości minimaksowe pozycji



○ – ruch gracza *Max*

□ – ruch gracza *Min*


Który ruch wykonać? – wartości minimaksowe pozycji



○ – ruch gracza *Max*

□ – ruch gracza *Min*


Który ruch wykonać? – wartości minimaksowe pozycji



○ – ruch gracza *Max*

□ – ruch gracza *Min*


Który ruch wykonać? – wartości minimaksowe pozycji



○ – ruch gracza *Max*

□ – ruch gracza *Min*


Który ruch wykonać? – wartości minimaksowe pozycji



○ – ruch gracza *Max*

□ – ruch gracza *Min*


Który ruch wykonać? – wartości minimaksowe pozycji



○ – ruch gracza *Max*

□ – ruch gracza *Min*


Który ruch wykonać? – wartości minimaksowe pozycji



○ – ruch gracza *Max*

□ – ruch gracza *Min*

Który ruch wykonać? – wartości minimaksowe pozycji



○ – ruch gracza *Max*

□ – ruch gracza *Min*

Szacowana złożoność wybranych gier

gra	logarytm dziesiętny ze złożoności przestrzeni stanów ¹ drzewa gry ²	
Kółko i krzyżyk (3x3)	3	5
Czwórki (Connect Four, 7x6)	13	21
Rozgrywka w widne w brydżu (średnia dla 13 lew)	17	29
Warcaby amerykańskie	18	31
Othello (8x8)	28	58
Szachy	47	123
Go (19x19)	171	360

Źródła: [Allis 1994], [Herik 2002], [Beling doktorat]

W przypadku wielu gier, czas pracy algorytmu z poprzedniego slajdu jest nieakceptowalny.

¹liczba różnych pozycji osiągalnych z pozycji początkowej

²liczba liści w drzewie minimaxowym o głębokości ograniczonej do minimum niezbędnego do ustalenia wartości pozycji początkowej

Szacowana złożoność wybranych gier

gra	logarytm dziesiętny ze złożoności przestrzeni stanów ¹ drzewa gry ²	
Kółko i krzyżyk (3x3)	3	5
Czwórki (Connect Four, 7x6)	13	21
Rozgrywka w widne w brydżu (średnia dla 13 lew)	17	29
Warcaby amerykańskie	18	31
Othello (8x8)	28	58
Szachy	47	123
Go (19x19)	171	360

Źródła: [Allis 1994], [Herik 2002], [Beling doktorat]


W przypadku wielu gier, czas pracy algorytmu z poprzedniego slajdu jest nieakceptowalny.

¹liczba różnych pozycji osiągalnych z pozycji początkowej

²liczba liści w drzewie minimaxowym o głębokości ograniczonej do minimum niezbędnego do ustalenia wartości pozycji początkowej


Ograniczenie głębokości poszukiwań

- ▶ drzewo poszukiwań ograniczone do zadanej głębokości
- ▶ po jej osiągnięciu wartość pozycji jest szacowana heurystycznie (przy wykorzystaniu wiedzy dziedzinowej)
- ▶ siła gry rośnie wraz z trafnością tego szacowania oraz głębokością poszukiwań




Ograniczenie głębokości poszukiwań

- ▶ drzewo poszukiwań ograniczone do zadanej głębokości
- ▶ po jej osiągnięciu wartość pozycji jest szacowana heurystycznie (przy wykorzystaniu wiedzy dziedzinowej)
- ▶ siła gry rośnie wraz z trafnością tego szacowania oraz głębokością poszukiwań



Ograniczenie głębokości poszukiwań

- ▶ drzewo poszukiwań ograniczone do zadanej głębokości
- ▶ po jej osiągnięciu wartość pozycji jest szacowana heurystycznie (przy wykorzystaniu wiedzy dziedzinowej)
- ▶ siła gry rośnie wraz z trafnością tego szacowania oraz głębokością poszukiwań



Algorytm α - β [Knuth 1975] – idea

- ▶ założmy, że w pozycji P ruch należy do gracza Max
- ▶ i wiadomo, że wartość jednego z następników P wynosi α ;
- ▶ zatem wartość P to co najmniej α
- ▶ i do jej wyznaczenia nie potrzebujemy znać dokładnych wartości następników o wartościach nie większych od α ;
- ▶ analogicznie, jeżeli w pozycji P ruch należy do gracza Min , to nie potrzebujemy znać dokładnych wartości następników P nie mniejszych od dotychczas znalezionej minimum β ;
- ▶ w ten sposób otrzymujemy i następnie, idąc w głąb drzewa poszukiwań, zawężamy przedział (zwany też „oknem”) wartości (α, β) ;
- ▶ przeszukiwanie węzła można przerwać gdy tylko zorientujemy się, że jego wartość nie mieści się w oknie (α, β) .

Algorytm α - β [Knuth 1975] – idea

- ▶ założmy, że w pozycji P ruch należy do gracza Max
- ▶ i wiadomo, że wartość jednego z następników P wynosi α ;
- ▶ zatem wartość P to co najmniej α
- ▶ i do jej wyznaczenia nie potrzebujemy znać dokładnych wartości następników o wartościach nie większych od α ;
- ▶ analogicznie, jeżeli w pozycji P ruch należy do gracza Min , to nie potrzebujemy znać dokładnych wartości następników P nie mniejszych od dotychczas znalezionej minimum β ;
- ▶ w ten sposób otrzymujemy i następnie, idąc w głąb drzewa poszukiwań, zawężamy przedział (zwany też „oknem”) wartości (α, β) ;
- ▶ przeszukiwanie węzła można przerwać gdy tylko zorientujemy się, że jego wartość nie mieści się w oknie (α, β) .

Algorytm α - β [Knuth 1975] – idea

- ▶ założmy, że w pozycji P ruch należy do gracza Max
- ▶ i wiadomo, że wartość jednego z następników P wynosi α ;
- ▶ zatem wartość P to co najmniej α
- ▶ i do jej wyznaczenia nie potrzebujemy znać dokładnych wartości następników o wartościach nie większych od α ;
- ▶ analogicznie, jeżeli w pozycji P ruch należy do gracza Min , to nie potrzebujemy znać dokładnych wartości następników P nie mniejszych od dotychczas znalezionej minimum β ;
- ▶ w ten sposób otrzymujemy i następnie, idąc w głąb drzewa poszukiwań, zawężamy przedział (zwany też „oknem”) wartości (α, β) ;
- ▶ przeszukiwanie węzła można przerwać gdy tylko zorientujemy się, że jego wartość nie mieści się w oknie (α, β) .

Algorytm α - β [Knuth 1975] – idea

- ▶ założmy, że w pozycji P ruch należy do gracza Max
- ▶ i wiadomo, że wartość jednego z następników P wynosi α ;
- ▶ zatem wartość P to co najmniej α
- ▶ i do jej wyznaczenia nie potrzebujemy znać dokładnych wartości następników o wartościach nie większych od α ;
- ▶ analogicznie, jeżeli w pozycji P ruch należy do gracza Min , to nie potrzebujemy znać dokładnych wartości następników P nie mniejszych od dotychczas znalezionej minimum β ;
- ▶ w ten sposób otrzymujemy i następnie, idąc w głąb drzewa poszukiwań, zawężamy przedział (zwany też „oknem”) wartości (α, β) ;
- ▶ przeszukiwanie węzła można przerwać gdy tylko zorientujemy się, że jego wartość nie mieści się w oknie (α, β) .

Algorytm α - β [Knuth 1975] – idea

- ▶ założmy, że w pozycji P ruch należy do gracza Max
- ▶ i wiadomo, że wartość jednego z następników P wynosi α ;
- ▶ zatem wartość P to co najmniej α
- ▶ i do jej wyznaczenia nie potrzebujemy znać dokładnych wartości następników o wartościach nie większych od α ;
- ▶ analogicznie, jeżeli w pozycji P ruch należy do gracza Min , to nie potrzebujemy znać dokładnych wartości następników P nie mniejszych od dotychczas znalezionej minimum β ;
- ▶ w ten sposób otrzymujemy i następnie, idąc w głąb drzewa poszukiwań, zawężamy przedział (zwany też „oknem”) wartości (α, β) ;
- ▶ przeszukiwanie węzła można przerwać gdy tylko zorientujemy się, że jego wartość nie mieści się w oknie (α, β) .


Algorytm α - β [Knuth 1975] – idea

- ▶ założmy, że w pozycji P ruch należy do gracza Max
- ▶ i wiadomo, że wartość jednego z następników P wynosi α ;
- ▶ zatem wartość P to co najmniej α
- ▶ i do jej wyznaczenia nie potrzebujemy znać dokładnych wartości następników o wartościach nie większych od α ;
- ▶ analogicznie, jeżeli w pozycji P ruch należy do gracza Min , to nie potrzebujemy znać dokładnych wartości następników P nie mniejszych od dotychczas znalezionej minimum β ;
- ▶ w ten sposób otrzymujemy i następnie, idąc w głąb drzewa poszukiwań, zawężamy przedział (zwany też „oknem”) wartości (α, β) ;
- ▶ przeszukiwanie węzła można przerwać gdy tylko zorientujemy się, że jego wartość nie mieści się w oknie (α, β) .

Algorytm α - β [Knuth 1975] – idea


- ▶ założmy, że w pozycji P ruch należy do gracza Max
- ▶ i wiadomo, że wartość jednego z następników P wynosi α ;
- ▶ zatem wartość P to co najmniej α
- ▶ i do jej wyznaczenia nie potrzebujemy znać dokładnych wartości następników o wartościach nie większych od α ;
- ▶ analogicznie, jeżeli w pozycji P ruch należy do gracza Min , to nie potrzebujemy znać dokładnych wartości następników P nie mniejszych od dotychczas znalezionej minimum β ;
- ▶ w ten sposób otrzymujemy i następnie, idąc w głąb drzewa poszukiwań, zawężamy przedział (zwany też „oknem”) wartości (α, β) ;
- ▶ przeszukiwanie węzła można przerwać gdy tylko zorientujemy się, że jego wartość nie mieści się w oknie (α, β) .

Algorytm α - β [Knuth 1975] – przykład




○ – ruch gracza *Max* □ – ruch gracza *Min*

Algorytm α - β [Knuth 1975] – przykład




○ – ruch gracza *Max* □ – ruch gracza *Min*

Algorytm α - β [Knuth 1975] – przykład




○ – ruch gracza *Max* □ – ruch gracza *Min*

Algorytm α - β [Knuth 1975] – przykład




○ – ruch gracza *Max* □ – ruch gracza *Min*

Algorytm α - β [Knuth 1975] – przykład




○ – ruch gracza *Max* □ – ruch gracza *Min*

Algorytm α - β [Knuth 1975] – przykład




○ – ruch gracza *Max* □ – ruch gracza *Min*

Algorytm α - β [Knuth 1975] – przykład




○ – ruch gracza *Max* □ – ruch gracza *Min*

Algorytm α - β [Knuth 1975] – przykład




Algorytm α - β [Knuth 1975] – przykład




○ – ruch gracza *Max* □ – ruch gracza *Min*

Algorytm α - β [Knuth 1975] – przykład




○ – ruch gracza *Max* □ – ruch gracza *Min*

Algorytm α - β [Knuth 1975] – przykład




○ – ruch gracza *Max* □ – ruch gracza *Min*

Algorytm α - β [Knuth 1975] – przykład




○ – ruch gracza *Max* □ – ruch gracza *Min*

Algorytm α - β [Knuth 1975] – przykład



○ – ruch gracza *Max* □ – ruch gracza *Min*


Algorytm α - β [Knuth 1975] – przykład



○ – ruch gracza *Max* □ – ruch gracza *Min*


Tablica Transpozycji

- ▶ cel: uniknie redundantnych obliczeń;
- ▶ **transpozycja** – różne sekwencje ruchów prowadzą do tej samej pozycji;
- ▶ **tablica transpozycji** zawiera wyniki uzyskane dla dotychczas zbadanych pozycji.




Tablica Transpozycji

- ▶ cel: uniknie redundantnych obliczeń;
- ▶ **transpozycja** – różne sekwencje ruchów prowadzą do tej samej pozycji;
- ▶ **tablica transpozycji** zawiera wyniki uzyskane dla dotychczas zbadanych pozycji.




Tablica Transpozycji

- ▶ cel: uniknie redundantnych obliczeń;
- ▶ **transpozycja** – różne sekwencje ruchów prowadzą do tej samej pozycji;
- ▶ **tablica transpozycji** zawiera wyniki uzyskane dla dotychczas zbadanych pozycji.




Monte Carlo Tree Search [Kocsis 2006] – przegląd



MCTS trzyma w pamięci i przyrostowo buduje drzewo poszukiwań, wykonując w pętli, dopóki jest czas:

1. wybór liścia L – preferencja najbardziej prawdopodobnych oraz najślabiej zbadanych przebiegów gry;
2. rozrost – warunkowe dodanie do drzewa następników L ;
3. symulacja – dokończenie rozgrywki (zazwyczaj losowe);
4. propagacja wstecz – na podstawie wyniku rozgrywki aktualizowane są informacje (wykorzystywane na etapie wyboru) o węzłach na ścieżce od korzenia do L .


Monte Carlo Tree Search [Kocsis 2006] – przegląd



MCTS trzyma w pamięci i przyrostowo buduje drzewo poszukiwań, wykonując w pętli, dopóki jest czas:

1. wybór liścia L – preferencja najbardziej prawdopodobnych oraz najślabiej zbadanych przebiegów gry;
2. rozrost – warunkowe dodanie do drzewa następników L ;
3. symulacja – dokończenie rozgrywki (zazwyczaj losowe);
4. propagacja wstecz – na podstawie wyniku rozgrywki aktualizowane są informacje (wykorzystywane na etapie wyboru) o węzłach na ścieżce od korzenia do L .


Monte Carlo Tree Search [Kocsis 2006] – przegląd



MCTS trzyma w pamięci i przyrostowo buduje drzewo poszukiwań, wykonując w pętli, dopóki jest czas:

1. wybór liścia L – preferencja najbardziej prawdopodobnych oraz najślabiej zbadanych przebiegów gry;
2. rozrost – warunkowe dodanie do drzewa następników L ;
3. symulacja – dokończenie rozgrywki (zazwyczaj losowe);
4. propagacja wstecz – na podstawie wyniku rozgrywki aktualizowane są informacje (wykorzystywane na etapie wyboru) o węzłach na ścieżce od korzenia do L .

Monte Carlo Tree Search [Kocsis 2006] – przegląd



MCTS trzyma w pamięci i przyrostowo buduje drzewo poszukiwań, wykonując w pętli, dopóki jest czas:

1. wybór liścia L – preferencja najbardziej prawdopodobnych oraz najślabiej zbadanych przebiegów gry;
2. rozrost – warunkowe dodanie do drzewa następników L ;
3. symulacja – dokończenie rozgrywki (zazwyczaj losowe);
4. propagacja wstecz – na podstawie wyniku rozgrywki aktualizowane są informacje (wykorzystywane na etapie wyboru) o węzłach na ścieżce od korzenia do L .

Monte Carlo Tree Search – drzewo

MCTS trzyma w pamięci i przyrostowo buduje drzewo (oznaczymy je T) będące spójnym fragmentem drzewa poszukiwań algorytmu Min-Max.

Początkowo T składa się jedynie z korzenia r , który reprezentuje pozycję dla której chcemy znaleźć suboptymalny ruch, oraz z jej synów.

Dla każdego węzła w w drzewie T pamiętane są dwie wartości:

- ▶ n_w – liczba dotychczasowych rozgrywek, które przebiegły przez w ,
- ▶ v_w – suma wartości minimaksowych z tych rozgrywek (w przypadku gier typu wygrana-przegrana: liczba zwycięstw gracza Max w tych rozgrywkach).

Dla nowo dodanego do T węzła, obie te wartości inicjowane są liczbą 0.

Gdy $n_w > 0$, wartość minimaksową węzła w można oszacować ilorazem v_w/n_w . Pewność szacowania rośnie wraz z n_w .

Monte Carlo Tree Search – drzewo

MCTS trzyma w pamięci i przyrostowo buduje drzewo (oznaczymy je T) będące spójnym fragmentem drzewa poszukiwań algorytmu Min-Max.

Początkowo T składa się jedynie z korzenia r , który reprezentuje pozycję dla której chcemy znaleźć suboptymalny ruch, oraz z jej synów.

Dla każdego węzła w w drzewie T pamiętane są dwie wartości:

- ▶ n_w – liczba dotychczasowych rozgrywek, które przebiegły przez w ,
- ▶ v_w – suma wartości minimaksowych z tych rozgrywek (w przypadku gier typu wygrana-przegrana: liczba zwycięstw gracza Max w tych rozgrywkach).

Dla nowo dodanego do T węzła, obie te wartości inicjowane są liczbą 0.

Gdy $n_w > 0$, wartość minimaksową węzła w można oszacować ilorazem v_w/n_w . Pewność szacowania rośnie wraz z n_w .

Monte Carlo Tree Search – drzewo

MCTS trzyma w pamięci i przyrostowo buduje drzewo (oznaczymy je T) będące spójnym fragmentem drzewa poszukiwań algorytmu Min-Max.

Początkowo T składa się jedynie z korzenia r , który reprezentuje pozycję dla której chcemy znaleźć suboptymalny ruch, oraz z jej synów.

Dla każdego węzła w w drzewie T pamiętane są dwie wartości:

- ▶ n_w – liczba dotychczasowych rozgrywek, które przebiegły przez w ,
- ▶ v_w – suma wartości minimaksowych z tych rozgrywek (w przypadku gier typu wygrana-przegrana: liczba zwycięstw gracza Max w tych rozgrywkach).

Dla nowo dodanego do T węzła, obie te wartości inicjowane są liczbą 0.

Gdy $n_w > 0$, wartość minimaksową węzła w można oszacować ilorazem v_w/n_w . Pewność szacowania rośnie wraz z n_w .

Monte Carlo Tree Search – drzewo

MCTS trzyma w pamięci i przyrostowo buduje drzewo (oznaczymy je T) będące spójnym fragmentem drzewa poszukiwań algorytmu Min-Max.

Początkowo T składa się jedynie z korzenia r , który reprezentuje pozycję dla której chcemy znaleźć suboptymalny ruch, oraz z jej synów.

Dla każdego węzła w w drzewie T pamiętane są dwie wartości:

- ▶ n_w – liczba dotychczasowych rozgrywek, które przebiegły przez w ,
- ▶ v_w – suma wartości minimaksowych z tych rozgrywek (w przypadku gier typu wygrana-przegrana: liczba zwycięstw gracza Max w tych rozgrywkach).

Dla nowo dodanego do T węzła, obie te wartości inicjowane są liczbą 0.

Gdy $n_w > 0$, wartość minimaksową węzła w można oszacować ilorazem v_w/n_w . Pewność szacowania rośnie wraz z n_w .

Monte Carlo Tree Search – drzewo

MCTS trzyma w pamięci i przyrostowo buduje drzewo (oznaczymy je T) będące spójnym fragmentem drzewa poszukiwań algorytmu Min-Max.

Początkowo T składa się jedynie z korzenia r , który reprezentuje pozycję dla której chcemy znaleźć suboptymalny ruch, oraz z jej synów.

Dla każdego węzła w w drzewie T pamiętane są dwie wartości:

- ▶ n_w – liczba dotychczasowych rozgrywek, które przebiegły przez w ,
- ▶ v_w – suma wartości minimaksowych z tych rozgrywek (w przypadku gier typu wygrana-przegrana: liczba zwycięstw gracza Max w tych rozgrywkach).

Dla nowo dodanego do T węzła, obie te wartości inicjowane są liczbą 0.

Gdy $n_w > 0$, wartość minimaksową węzła w można oszacować ilorazem v_w/n_w . Pewność szacowania rośnie wraz z n_w .

Monte Carlo Tree Search – wybór liścia

Wybór jednego z liści drzewa T (oznaczymy tego liścia literą l).

Algorytm schodzi w dół drzewa T startując z korzenia r

i wybierając spośród następników każdego węzła w , taki węzeł x , który:

- ▶ albo nie był dotychczas wybrany (tj. spełniający $n_x = 0$),
- ▶ albo, gdy wszystkie następniki w były wcześniej co najmniej raz wybrane, optymalizuje pewną funkcję f (maksymalizuje albo minimalizuje ją w zależności od tego czy ruch w należy do gracza Max czy Min).

Monte Carlo Tree Search – wybór liścia

Wybór jednego z liści drzewa T (oznaczymy tego liścia literą l).

Algorytm schodzi w dół drzewa T startując z korzenia r

i wybierając spośród następników każdego węzła w , taki węzeł x , który:

- ▶ albo nie był dotychczas wybrany (tj. spełniający $n_x = 0$),
- ▶ albo, gdy wszystkie następniki w były wcześniej co najmniej raz wybrane, optymalizuje pewną funkcję f (maksymalizuje albo minimalizuje ją w zależności od tego czy ruch w należy do gracza Max czy Min).

Monte Carlo Tree Search – wybór liścia

Wybór jednego z liści drzewa T (oznaczymy tego liścia literą l).

Algorytm schodzi w dół drzewa T startując z korzenia r

i wybierając spośród następników każdego węzła w , taki węzeł x , który:

- ▶ albo nie był dotychczas wybrany (tj. spełniający $n_x = 0$),
- ▶ albo, gdy wszystkie następniki w były wcześniej co najmniej raz wybrane, optymalizuje pewną funkcję f (maksymalizuje albo minimalizuje ją w zależności od tego czy ruch w należy do gracza Max czy Min).

Monte Carlo Tree Search – wybór liścia

Wybór jednego z liści drzewa T (oznaczymy tego liścia literą l).

Algorytm schodzi w dół drzewa T startując z korzenia r

i wybierając spośród następników każdego węzła w , taki węzeł x , który:

- ▶ albo nie był dotychczas wybrany (tj. spełniający $n_x = 0$),
- ▶ albo, gdy wszystkie następniki w były wcześniej co najmniej raz wybrane, optymalizuje pewną funkcję f (maksymalizuje albo minimalizuje ją w zależności od tego czy ruch w należy do gracza Max czy Min).

Monte Carlo Tree Search – UCT

Funkcja f jest tak skonstruowana, że wartość $f(x)$ (dla x spełniającego $n_x > 0$):

- ▶ rośnie wraz z szacowaną wartością minimaxową x (tj. wraz z ilorazem v_x/n_x) – cel: częstsze wybieranie i dokładniejsze zbadanie bardziej prawdopodobnych przebiegów gry.
- ▶ równocześnie f powinna faworyzować także węzły słabo zbadane (o stosunkowo niskiej wartości n_x), dla których wspomniane szacowanie jest niepewne.

Najpopularniejsza odmiana MCTS zwana UCT (Upper Confidence Bounds for Trees), używa funkcji f w postaci zaproponowanej w [Kocsis 2006], znanej pod nazwą UCB (Upper Confidence Bounds):

$$f(x) = \begin{cases} \frac{v_x}{n_x} + c\sqrt{\frac{\ln n_w}{n_x}} & \text{gdy } w \text{ w idzie Max,} \\ \frac{v_x}{n_x} - c\sqrt{\frac{\ln n_w}{n_x}} & \text{gdy } w \text{ w idzie Min,} \end{cases}$$

gdzie $c > 0$ to stała, najczęściej dobierana eksperymentalnie (jedna z proponowanych wartości wynosi $\sqrt{2}$), zaś w jest ojcem węzła x w drzewie T .

Monte Carlo Tree Search – UCT

Funkcja f jest tak skonstruowana, że wartość $f(x)$

(dla x spełniającego $n_x > 0$):

- ▶ rośnie wraz z szacowaną wartością minimaxową x (tj. wraz z ilorazem v_x/n_x) – cel: częstsze wybieranie i dokładniejsze zbadanie bardziej prawdopodobnych przebiegów gry.
- ▶ równocześnie f powinna faworyzować także węzły słabo zbadane (o stosunkowo niskiej wartości n_x), dla których wspomniane szacowanie jest niepewne.

Najpopularniejsza odmiana MCTS zwana UCT (Upper Confidence Bounds for Trees), używa funkcji f w postaci zaproponowanej w [Kocsis 2006], znanej pod nazwą UCB (Upper Confidence Bounds):

$$f(x) = \begin{cases} \frac{v_x}{n_x} + c\sqrt{\frac{\ln n_w}{n_x}} & \text{gdy } w \text{ w idzie Max,} \\ \frac{v_x}{n_x} - c\sqrt{\frac{\ln n_w}{n_x}} & \text{gdy } w \text{ w idzie Min,} \end{cases}$$

gdzie $c > 0$ to stała, najczęściej dobierana eksperymentalnie (jedna z proponowanych wartości wynosi $\sqrt{2}$), zaś w jest ojcem węzła x w drzewie T .

Monte Carlo Tree Search – UCT

Funkcja f jest tak skonstruowana, że wartość $f(x)$

(dla x spełniającego $n_x > 0$):

- ▶ rośnie wraz z szacowaną wartością minimaxową x (tj. wraz z ilorazem v_x/n_x) – cel: częstsze wybieranie i dokładniejsze zbadanie bardziej prawdopodobnych przebiegów gry.
- ▶ równocześnie f powinna faworyzować także węzły słabo zbadane (o stosunkowo niskiej wartości n_x), dla których wspomniane szacowanie jest niepewne.

Najpopularniejsza odmiana MCTS zwana UCT (Upper Confidence Bounds for Trees), używa funkcji f w postaci zaproponowanej w [Kocsis 2006], znanej pod nazwą UCB (Upper Confidence Bounds):

$$f(x) = \begin{cases} \frac{v_x}{n_x} + c\sqrt{\frac{\ln n_w}{n_x}} & \text{gdy } w \text{ w idzie Max,} \\ \frac{v_x}{n_x} - c\sqrt{\frac{\ln n_w}{n_x}} & \text{gdy } w \text{ w idzie Min,} \end{cases}$$

gdzie $c > 0$ to stała, najczęściej dobierana eksperymentalnie (jedna z proponowanych wartości wynosi $\sqrt{2}$), zaś w jest ojcem węzła x w drzewie T .

Monte Carlo Tree Search – UCT

Funkcja f jest tak skonstruowana, że wartość $f(x)$ (dla x spełniającego $n_x > 0$):

- ▶ rośnie wraz z szacowaną wartością minimaxową x (tj. wraz z ilorazem v_x/n_x) – cel: częstsze wybieranie i dokładniejsze zbadanie bardziej prawdopodobnych przebiegów gry.
- ▶ równocześnie f powinna faworyzować także węzły słabo zbadane (o stosunkowo niskiej wartości n_x), dla których wspomniane szacowanie jest niepewne.

Najpopularniejsza odmiana MCTS zwana UCT (Upper Confidence Bounds for Trees), używa funkcji f w postaci zaproponowanej w [Kocsis 2006], znanej pod nazwą UCB (Upper Confidence Bounds):

$$f(x) = \begin{cases} \frac{v_x}{n_x} + c\sqrt{\frac{\ln n_w}{n_x}} & \text{gdy } w \text{ w idzie Max,} \\ \frac{v_x}{n_x} - c\sqrt{\frac{\ln n_w}{n_x}} & \text{gdy } w \text{ w idzie Min,} \end{cases}$$

gdzie $c > 0$ to stała, najczęściej dobierana eksperymentalnie (jedna z proponowanych wartości wynosi $\sqrt{2}$), zaś w jest ojcem węzła x w drzewie T .

Monte Carlo Tree Search – ekspansja

Ekspansja (rozrost):

- ▶ dodanie do drzewa T następników węzła l ;
- ▶ może nastąpić tylko gdy l reprezentuje niekończącą pozycję gry;
- ▶ by zapobiec nadmiernemu rozrastaniu się drzewa T , zazwyczaj dokonuje się jej gdy zajądą dodatkowe warunki, np. gdy liczba n_l przekroczy pewien ustalony próg.

Jeśli ekspansja nastąpiła, to dalej przez l będziemy oznaczać liścia wybranego losowo spośród dodanych w jej wyniku do T .

Monte Carlo Tree Search – ekspansja

Ekspansja (rozrost):

- ▶ dodanie do drzewa T następników węzła l ;
- ▶ może nastąpić tylko gdy l reprezentuje niekończącą pozycję gry;
- ▶ by zapobiec nadmiernemu rozrastaniu się drzewa T , zazwyczaj dokonuje się jej gdy zajądą dodatkowe warunki, np. gdy liczba n_l przekroczy pewien ustalony próg.

Jeśli ekspansja nastąpiła, to dalej przez l będziemy oznaczać liścia wybranego losowo spośród dodanych w jej wyniku do T .

Monte Carlo Tree Search – ekspansja

Ekspansja (rozrost):

- ▶ dodanie do drzewa T następników węzła l ;
- ▶ może nastąpić tylko gdy l reprezentuje niekończącą pozycję gry;
- ▶ by zapobiec nadmiernemu rozrastaniu się drzewa T , zazwyczaj dokonuje się jej gdy zajądą dodatkowe warunki, np. gdy liczba n_l przekroczy pewien ustalony próg.

Jeśli ekspansja nastąpiła, to dalej przez l będziemy oznaczać liścia wybranego losowo spośród dodanych w jej wyniku do T .

Monte Carlo Tree Search – ekspansja

Ekspansja (rozrost):

- ▶ dodanie do drzewa T następników wężła l ;
- ▶ może nastąpić tylko gdy l reprezentuje niekończącą pozycję gry;
- ▶ by zapobiec nadmiernemu rozrastaniu się drzewa T , zazwyczaj dokonuje się jej gdy zajądą dodatkowe warunki, np. gdy liczba n_l przekroczy pewien ustalony próg.

Jeśli ekspansja nastąpiła, to dalej przez l będziemy oznaczać liścia wybranego losowo spośród dodanych w jej wyniku do T .

Monte Carlo Tree Search – ekspansja

Ekspansja (rozrost):

- ▶ dodanie do drzewa T następników węzła l ;
- ▶ może nastąpić tylko gdy l reprezentuje niekończącą pozycję gry;
- ▶ by zapobiec nadmiernemu rozrastaniu się drzewa T , zazwyczaj dokonuje się jej gdy zajądą dodatkowe warunki, np. gdy liczba n_l przekroczy pewien ustalony próg.

Jeśli ekspansja nastąpiła, to dalej przez l będziemy oznaczać liścia wybranego losowo spośród dodanych w jej wyniku do T .

Monte Carlo Tree Search – symulacja i propagacja

Dokończenie rozgrywki (symulacja)

- ▶ wykonanie kolejnych ruchów, zaczynając od pozycji l i kończąc w pewnej końcowej pozycji t ;
- ▶ ruchy mogą być wybierane całkowicie losowo;
- ▶ rozkład prawdopodobieństwa można uzależnić od specyficznej dla rozpatrywanej gry heurystyki, aby częściej wybierać ruchy poprawne z punktu widzenia wykonujących je uczestników – wzrośnie realizm symulowanych rozgrywek i, co za tym idzie, siła całego algorytmu.

Propagacja wstecz

Aktualizacja wartości n_w i v_w dla każdego węzła w na ścieżce od korzenia r do wybranego liścia l , zwiększenie:

- ▶ n_w o 1;
- ▶ v_w o wypłatę gracza Max po zakończeniu gry w pozycji t (zazwyczaj 1 gdy wygrał, 0 gdy przegrał).

Monte Carlo Tree Search – symulacja i propagacja

Dokończenie rozgrywki (symulacja)

- ▶ wykonanie kolejnych ruchów, zaczynając od pozycji l i kończąc w pewnej końcowej pozycji t ;
- ▶ ruchy mogą być wybierane całkowicie losowo;
- ▶ rozkład prawdopodobieństwa można uzależnić od specyficznej dla rozpatrywanej gry heurystyki, aby częściej wybierać ruchy poprawne z punktu widzenia wykonujących je uczestników – wzrośnie realizm symulowanych rozgrywek i, co za tym idzie, siła całego algorytmu.

Propagacja wstecz

Aktualizacja wartości n_w i v_w dla każdego węzła w na ścieżce od korzenia r do wybranego liścia l , zwiększenie:

- ▶ n_w o 1;
- ▶ v_w o wypłatę gracza Max po zakończeniu gry w pozycji t (zazwyczaj 1 gdy wygrał, 0 gdy przegrał).

Monte Carlo Tree Search – symulacja i propagacja

Dokończenie rozgrywki (symulacja)

- ▶ wykonanie kolejnych ruchów, zaczynając od pozycji l i kończąc w pewnej końcowej pozycji t ;
- ▶ ruchy mogą być wybierane całkowicie losowo;
- ▶ rozkład prawdopodobieństwa można uzależnić od specyficznej dla rozpatrywanej gry heurystyki, aby częściej wybierać ruchy poprawne z punktu widzenia wykonujących je uczestników – wzrośnie realizm symulowanych rozgrywek i, co za tym idzie, siła całego algorytmu.

Propagacja wstecz

Aktualizacja wartości n_w i v_w dla każdego węzła w na ścieżce od korzenia r do wybranego liścia l , zwiększenie:

- ▶ n_w o 1;
- ▶ v_w o wypłatę gracza Max po zakończeniu gry w pozycji t (zazwyczaj 1 gdy wygrał, 0 gdy przegrał).

Monte Carlo Tree Search – symulacja i propagacja

Dokończenie rozgrywki (symulacja)

- ▶ wykonanie kolejnych ruchów, zaczynając od pozycji l i kończąc w pewnej końcowej pozycji t ;
- ▶ ruchy mogą być wybierane całkowicie losowo;
- ▶ rozkład prawdopodobieństwa można uzależnić od specyficznej dla rozpatrywanej gry heurystyki, aby częściej wybierać ruchy poprawne z punktu widzenia wykonujących je uczestników – wzrośnie realizm symulowanych rozgrywek i, co za tym idzie, siła całego algorytmu.

Propagacja wstecz

Aktualizacja wartości n_w i v_w dla każdego węzła w na ścieżce od korzenia r do wybranego liścia l , zwiększenie:

- ▶ $n_w \leftarrow n_w + 1$;
- ▶ $v_w \leftarrow v_w + \frac{1}{n_w} (v_t - v_w)$ (zazwyczaj 1 gdy wygrał, 0 gdy przegrał).

Monte Carlo Tree Search – symulacja i propagacja

Dokończenie rozgrywki (symulacja)

- ▶ wykonanie kolejnych ruchów, zaczynając od pozycji l i kończąc w pewnej końcowej pozycji t ;
- ▶ ruchy mogą być wybierane całkowicie losowo;
- ▶ rozkład prawdopodobieństwa można uzależnić od specyficznej dla rozpatrywanej gry heurystyki, aby częściej wybierać ruchy poprawne z punktu widzenia wykonujących je uczestników – wzrośnie realizm symulowanych rozgrywek i, co za tym idzie, siła całego algorytmu.

Propagacja wstecz

Aktualizacja wartości n_w i v_w dla każdego węzła w na ścieżce od korzenia r do wybranego liścia l , zwiększenie:

- ▶ n_w o 1;
- ▶ v_w o wypłatę gracza Max po zakończeniu gry w pozycji t (zazwyczaj 1 gdy wygrał, 0 gdy przegrał).

Monte Carlo Tree Search – symulacja i propagacja

Dokończenie rozgrywki (symulacja)

- ▶ wykonanie kolejnych ruchów, zaczynając od pozycji l i kończąc w pewnej końcowej pozycji t ;
- ▶ ruchy mogą być wybierane całkowicie losowo;
- ▶ rozkład prawdopodobieństwa można uzależnić od specyficznej dla rozpatrywanej gry heurystyki, aby częściej wybierać ruchy poprawne z punktu widzenia wykonujących je uczestników – wzrośnie realizm symulowanych rozgrywek i, co za tym idzie, siła całego algorytmu.

Propagacja wstecz

Aktualizacja wartości n_w i v_w dla każdego węzła w na ścieżce od korzenia r do wybranego liścia l , zwiększenie:

- ▶ n_w o 1;
- ▶ v_w o wypłatę gracza Max po zakończeniu gry w pozycji t (zazwyczaj 1 gdy wygrał, 0 gdy przegrał).

Monte Carlo Tree Search – wybór ruchu

Gdy skończy się czas na podjęcie decyzji, algorytm, spośród następników węzła r , wybiera taki ruch m , który maksymalizuje wartość:

- ▶ v_m / n_m
(najwyżej oceniany ruch);
- ▶ albo, alternatywnie, n_m
(najczęściej odwiedzany ruch $\approx$ najwyżej oceniany przez większość czasu pracy algorytmu);
- ▶ rzadziej stosuje się też inne kryterium.

Monte Carlo Tree Search – wybór ruchu

Gdy skończy się czas na podjęcie decyzji, algorytm, spośród następników węzła r , wybiera taki ruch m , który maksymalizuje wartość:

- ▶ v_m/n_m
(najwyżej oceniany ruch);
- ▶ albo, alternatywnie, n_m
(najczęściej odwiedzany ruch $\approx$ najwyżej oceniany przez większość czasu pracy algorytmu);
- ▶ rzadziej stosuje się też inne kryterium.

Monte Carlo Tree Search – wybór ruchu

Gdy skończy się czas na podjęcie decyzji, algorytm, spośród następników węzła r , wybiera taki ruch m , który maksymalizuje wartość:

- ▶ v_m/n_m
(najwyżej oceniany ruch);
- ▶ albo, alternatywnie, n_m
(najczęściej odwiedzany ruch $\approx$ najwyżej oceniany przez większość czasu pracy algorytmu);
- ▶ rzadziej stosuje się też inne kryterium.

Monte Carlo Tree Search – wybór ruchu

Gdy skończy się czas na podjęcie decyzji, algorytm, spośród następników węzła r , wybiera taki ruch m , który maksymalizuje wartość:

- ▶ v_m/n_m
(najwyżej oceniany ruch);
- ▶ albo, alternatywnie, n_m
(najczęściej odwiedzany ruch $\approx$ najwyżej oceniany przez większość czasu pracy algorytmu);
- ▶ rzadziej stosuje się też inne kryterium.

Monte Carlo Tree Search – główne zalety

- ▶ nie wymaga wiedzy dziedzinowej;
- ▶ jednocześnie pozwala taką wiedzę wykorzystać (na etapie selekcji oraz symulacji);
- ▶ możliwość podania aktualnego szacowania wyniku w dowolnym momencie, co umożliwia bardzo dokładne dostosowanie się do czasu dostępnego na podjęcie decyzji;
- ▶ możliwość dość łatwego zrównoleglenia obliczeń;

Przegląd różnych wariantów MCTS i ich zastosowań można znaleźć w [Browne 2012]

C. Browne, et al. *A Survey of Monte Carlo Tree Search Methods*, IEEE Transactions on Computational Intelligence and AI in Games, 2012, Volume 4, Issue 1

Monte Carlo Tree Search – główne zalety

- ▶ nie wymaga wiedzy dziedzinowej;
- ▶ jednocześnie pozwala taką wiedzę wykorzystać (na etapie selekcji oraz symulacji);
- ▶ możliwość podania aktualnego szacowania wyniku w dowolnym momencie, co umożliwia bardzo dokładne dostosowanie się do czasu dostępnego na podjęcie decyzji;
- ▶ możliwość dość łatwego zrównoleglenia obliczeń;

Przegląd różnych wariantów MCTS i ich zastosowań można znaleźć w [Browne 2012]

C. Browne, et al. *A Survey of Monte Carlo Tree Search Methods*, IEEE Transactions on Computational Intelligence and AI in Games, 2012, Volume 4, Issue 1

Monte Carlo Tree Search – główne zalety

- ▶ nie wymaga wiedzy dziedzinowej;
- ▶ jednocześnie pozwala taką wiedzę wykorzystać (na etapie selekcji oraz symulacji);
- ▶ możliwość podania aktualnego szacowania wyniku w dowolnym momencie, co umożliwia bardzo dokładne dostosowanie się do czasu dostępnego na podjęcie decyzji;
- ▶ możliwość dość łatwego zrównoleglenia obliczeń;

Przegląd różnych wariantów MCTS i ich zastosowań można znaleźć w [Browne 2012]

C. Browne, et al. *A Survey of Monte Carlo Tree Search Methods*, IEEE Transactions on Computational Intelligence and AI in Games, 2012, Volume 4, Issue 1

Monte Carlo Tree Search – główne zalety

- ▶ nie wymaga wiedzy dziedzinowej;
- ▶ jednocześnie pozwala taką wiedzę wykorzystać (na etapie selekcji oraz symulacji);
- ▶ możliwość podania aktualnego szacowania wyniku w dowolnym momencie, co umożliwia bardzo dokładne dostosowanie się do czasu dostępnego na podjęcie decyzji;
- ▶ możliwość dość łatwego zrównoleglenia obliczeń;

Przegląd różnych wariantów MCTS i ich zastosowań można znaleźć w [Browne 2012]

C. Browne, et al. *A Survey of Monte Carlo Tree Search Methods*, IEEE Transactions on Computational Intelligence and AI in Games, 2012, Volume 4, Issue 1


Monte Carlo Tree Search – główne zalety

- ▶ nie wymaga wiedzy dziedzinowej;
- ▶ jednocześnie pozwala taką wiedzę wykorzystać (na etapie selekcji oraz symulacji);
- ▶ możliwość podania aktualnego szacowania wyniku w dowolnym momencie, co umożliwia bardzo dokładne dostosowanie się do czasu dostępnego na podjęcie decyzji;
- ▶ możliwość dość łatwego zrównoleglenia obliczeń;

Przegląd różnych wariantów MCTS i ich zastosowań można znaleźć w [Browne 2012]

C. Browne, et al. *A Survey of Monte Carlo Tree Search Methods*, IEEE Transactions on Computational Intelligence and AI in Games, 2012, Volume 4, Issue 1

Niedoskonała informacja – zbiory informacyjne – przykład



Pierwszy gracz (Max) umieszcza przedmiot w lewej lub w prawej ręce, doprowadzając tym samym do pozycji *l* albo *p*. Drugi gracz (Min) wygra jeśli odgadnie w której ręce znajduje się przedmiot. Nie wie on jednak czy gra jest w pozycji *l* czy *p* (nie ma doskonałej informacji), co jest wyrażone poprzez umieszczenie obu pozycji we wspólnym zbiorze informacyjnym.

Determinizacja i PIMC

- ▶ **zbiór informacyjny** – zbiór pozycji w których może znajdować się w danej chwili gra,
- ▶ np. w grach karcianych w jednym zbiorze informacyjnym znajdą się pozycje o takim samym rozłożeniu kart widocznych dla gracza i różnym rozłożeniu kart niewidocznych;
- ▶ **determinizacja** – wybranie konkretnej pozycji ze zbioru informacyjnego (+ ewentualne ustalenie rezultatów wszelkich zdarzeń losowych);
także otrzymana w ten sposób **gra z doskonałą informacją** (i deterministyczna);
- ▶ **Perfect Information Monte Carlo (PIMC)** – metoda podejmowania decyzji w grach bez doskonałej informacji, polegająca na niezależnym rozwiązaniu szeregu determinizacji i wybraniu zagrania dla którego otrzymano najlepszy średni wynik.

Determinizacja i PIMC

- ▶ **zbiór informacyjny** – zbiór pozycji w których może znajdować się w danej chwili gra,
- ▶ np. w grach karcianych w jednym zbiorze informacyjnym znajdą się pozycje o takim samym rozłożeniu kart widocznych dla gracza i różnym rozłożeniu kart niewidocznych;
- ▶ **determinizacja** – wybranie konkretnej pozycji ze zbioru informacyjnego (+ ewentualne ustalenie rezultatów wszelkich zdarzeń losowych);
także otrzymana w ten sposób **gra z doskonałą informacją** (i deterministyczna);
- ▶ **Perfect Information Monte Carlo (PIMC)** – metoda podejmowania decyzji w grach bez doskonałej informacji, polegająca na niezależnym rozwiązaniu szeregu determinizacji i wybraniu zagrania dla którego otrzymano najlepszy średni wynik.


Determinizacja i PIMC

- ▶ **zbiór informacyjny** – zbiór pozycji w których może znajdować się w danej chwili gra,
- ▶ np. w grach karcianych w jednym zbiorze informacyjnym znajdą się pozycje o takim samym rozłożeniu kart widocznych dla gracza i różnym rozłożeniu kart niewidocznych;
- ▶ **determinizacja** – wybranie konkretnej pozycji ze zbioru informacyjnego (+ ewentualne ustalenie rezultatów wszelkich zdarzeń losowych);
także otrzymana w ten sposób **gra z doskonałą informacją** (i deterministyczna);
- ▶ **Perfect Information Monte Carlo (PIMC)** – metoda podejmowania decyzji w grach bez doskonałej informacji, polegająca na niezależnym rozwiązaniu szeregu determinizacji i wybraniu zagrania dla którego otrzymano najlepszy średni wynik.

Determinizacja i PIMC

- ▶ **zbiór informacyjny** – zbiór pozycji w których może znajdować się w danej chwili gra,
- ▶ np. w grach karcianych w jednym zbiorze informacyjnym znajdą się pozycje o takim samym rozłożeniu kart widocznych dla gracza i różnym rozłożeniu kart niewidocznych;
- ▶ **determinizacja** – wybranie konkretnej pozycji ze zbioru informacyjnego (+ ewentualne ustalenie rezultatów wszelkich zdarzeń losowych);
także otrzymana w ten sposób **gra z doskonałą informacją** (i deterministyczna);
- ▶ **Perfect Information Monte Carlo (PIMC)** – metoda podejmowania decyzji w grach bez doskonałej informacji, polegająca na niezależnym rozwiązaniu szeregu determinizacji i wybraniu zagrania dla którego otrzymano najlepszy średni wynik.


gra z niedoskonałą
informacją



Perfect Information
Monte Carlo


gra z niedoskonałą
informacją

Perfect Information
Monte Carlo




gra z niedoskonałą
informacją

Perfect Information
Monte Carlo




Problem łączenia strategii [Frank 1996]




- ruch wygrywający w każdej z pozycji (determinizacji) **z osobna** nie gwarantuje wygranej w grze bez doskonałej informacji;
- znalezione dla poszczególnych determinizacji (np. **A** i **B**) zwycięskie strategie, pomimo wspólnego pierwszego ruchu, **mogą później być niezgodne**;
- by znaleźć spójną strategię, poszczególne determinizacje trzeba badać **łącznie**;

Problem łączenia strategii [Frank 1996]




- ruch wygrywający w każdej z pozycji (determinizacji) **z osobna** nie gwarantuje wygranej w grze bez doskonałej informacji;
- znalezione dla poszczególnych determinizacji (np. **A** i **B**) zwycięskie strategie, pomimo wspólnego pierwszego ruchu, **mogą później być niezgodne**;
- by znaleźć spójną strategię, poszczególne determinizacje trzeba badać **łącznie**;

Problem łączenia strategii [Frank 1996]




- ruch wygrywający w każdej z pozycji (determinizacji) **z osobna** nie gwarantuje wygranej w grze bez doskonałej informacji;
- znalezione dla poszczególnych determinizacji (np. **A** i **B**) zwycięskie strategie, **pomimo wspólnego pierwszego ruchu, mogą później być niezgodne**;
- by znaleźć spójną strategię, poszczególne determinizacje trzeba badać **łącznie**;

Problem łączenia strategii [Frank 1996]



- ruch wygrywający w każdej z pozycji (determinizacji) z **osobna** nie gwarantuje wygranej w grze bez doskonałej informacji;
- znalezione dla poszczególnych determinizacji (np. **A** i **B**) zwycięskie strategie, pomimo wspólnego pierwszego ruchu, **mogą później być niezgodne**;
- by znaleźć spójną strategię, poszczególne determinizacje trzeba badać **łącznie**;

Problem łączenia strategii [Frank 1996]



- ruch wygrywający w każdej z pozycji (determinizacji) z **osobna** nie gwarantuje wygranej w grze bez doskonałej informacji;
- znalezione dla poszczególnych determinizacji (np. **A** i **B**) zwycięskie strategie, pomimo wspólnego pierwszego ruchu, **mogą później być niezgodne**;
- by znaleźć spójną strategię, poszczególne determinizacje trzeba badać **łącznie**;

MCTS dla gier bez doskonałej informacji

- ▶ MCTS (oraz jego odmianę UCT) można zaadaptować do gier bez doskonałej informacji,
- ▶ np. można go użyć do niezależnego rozwiązywania determinizacji w algorytmie PIMC,
- ▶ jednakże, wykorzystanie jednego, wspólnego drzewa T przy rozpatrywaniu kolejnych determinizacji, pozwala uzyskać silniejszą metodę, odporniejszą na problem łączenia strategii [Schäfer 2008]...

MCTS dla gier bez doskonałej informacji

- ▶ MCTS (oraz jego odmianę UCT) można zaadaptować do gier bez doskonałej informacji,
- ▶ np. można go użyć do niezależnego rozwiązywania determinizacji w algorytmie PIMC,
- ▶ jednakże, wykorzystanie jednego, wspólnego drzewa T przy rozpatrywaniu kolejnych determinizacji, pozwala uzyskać silniejszą metodę, odporniejszą na problem łączenia strategii [Schäfer 2008]...

MCTS dla gier bez doskonałej informacji

- ▶ MCTS (oraz jego odmianę UCT) można zaadaptować do gier bez doskonałej informacji,
- ▶ np. można go użyć do niezależnego rozwiązywania determinizacji w algorytmie PIMC,
- ▶ jednakże, wykorzystanie jednego, wspólnego drzewa T przy rozpatrywaniu kolejnych determinizacji, pozwala uzyskać silniejszą metodę, odporniejszą na problem łączenia strategii [Schäfer 2008]...

MCTS dla gier bez doskonałej informacji – wspólne drzewo

- ▶ każdy węzeł w drzewie T reprezentuje zbiór pozycji „nierozróżnialnych” z punktu widzenia gracza Max, przy tym:
 - ▶ albo ruch we wszystkich pozycjach ze zbioru należy do Maxa i wtedy jest to zbiór informacyjny,
 - ▶ albo ruch we wszystkich pozycjach ze zbioru należy do Mina i wtedy poszczególne pozycje mogą różnić się możliwymi do wykonania (przez Mina) ruchami,
- ▶ to z kolei wymusza modyfikacje MCTSa:
- ▶ na etapie selekcji trzeba ograniczyć wybór do zagrań dopuszczalnych w rozpatrywanej determinizacji,
- ▶ przeprowadzając ekspansję drzewa T , należy pamiętać o dodaniu następników niedostępnych w aktualnie rozpatrywanej determinizacji;
- ▶ w selekcji przez UCT, we wzorze na $f(x)$, liczbę n_w (liczba dotychczasowych rozgrywek, które przebiegły przez w – ojca węzła x), należy zastąpić liczbą dotychczasowych rozgrywek, które przebiegły przez w i w których ruch do x był dostępny.

MCTS dla gier bez doskonałej informacji – wspólne drzewo

- ▶ każdy węzeł w drzewie T reprezentuje zbiór pozycji „nierozróżnialnych” z punktu widzenia gracza Max, przy tym:
- ▶ albo ruch we wszystkich pozycjach ze zbioru należy do Maxa i wtedy jest to zbiór informacyjny,
- ▶ albo ruch we wszystkich pozycjach ze zbioru należy do Mina i wtedy poszczególne pozycje mogą różnić się możliwymi do wykonania (przez Mina) ruchami,
- ▶ to z kolei wymusza modyfikacje MCTSa:
- ▶ na etapie selekcji trzeba ograniczyć wybór do zagrań dopuszczalnych w rozpatrywanej determinizacji,
- ▶ przeprowadzając ekspansję drzewa T , należy pamiętać o dodaniu następników niedostępnych w aktualnie rozpatrywanej determinizacji;
- ▶ w selekcji przez UCT, we wzorze na $f(x)$, liczbę n_w (liczba dotychczasowych rozgrywek, które przebiegły przez w – ojca węzła x), należy zastąpić liczbą dotychczasowych rozgrywek, które przebiegły przez w i w których ruch do x był dostępny.

MCTS dla gier bez doskonałej informacji – wspólne drzewo

- ▶ każdy węzeł w drzewie T reprezentuje zbiór pozycji „nierozróżnialnych” z punktu widzenia gracza Max, przy tym:
- ▶ albo ruch we wszystkich pozycjach ze zbioru należy do Maxa i wtedy jest to zbiór informacyjny,
- ▶ albo ruch we wszystkich pozycjach ze zbioru należy do Mina i wtedy poszczególne pozycje mogą różnić się możliwymi do wykonania (przez Mina) ruchami,
- ▶ to z kolei wymusza modyfikacje MCTSa:
- ▶ na etapie selekcji trzeba ograniczyć wybór do zagrań dopuszczalnych w rozpatrywanej determinizacji,
- ▶ przeprowadzając ekspansję drzewa T , należy pamiętać o dodaniu następników niedostępnych w aktualnie rozpatrywanej determinizacji;
- ▶ w selekcji przez UCT, we wzorze na $f(x)$, liczbę n_w (liczba dotychczasowych rozgrywek, które przebiegły przez w – ojca węzła x), należy zastąpić liczbą dotychczasowych rozgrywek, które przebiegły przez w i w których ruch do x był dostępny.

MCTS dla gier bez doskonałej informacji – wspólne drzewo

- ▶ każdy węzeł w drzewie T reprezentuje zbiór pozycji „nierozróżnialnych” z punktu widzenia gracza Max, przy tym:
- ▶ albo ruch we wszystkich pozycjach ze zbioru należy do Maxa i wtedy jest to zbiór informacyjny,
- ▶ albo ruch we wszystkich pozycjach ze zbioru należy do Mina i wtedy poszczególne pozycje mogą różnić się możliwymi do wykonania (przez Mina) ruchami,
- ▶ to z kolei wymusza modyfikacje MCTSa:
- ▶ na etapie selekcji trzeba ograniczyć wybór do zagrań dopuszczalnych w rozpatrywanej determinizacji,
- ▶ przeprowadzając ekspansję drzewa T , należy pamiętać o dodaniu następników niedostępnych w aktualnie rozpatrywanej determinizacji;
- ▶ w selekcji przez UCT, we wzorze na $f(x)$, liczbę n_w (liczba dotychczasowych rozgrywek, które przebiegły przez w – ojca węzła x), należy zastąpić liczbą dotychczasowych rozgrywek, które przebiegły przez w i w których ruch do x był dostępny.

MCTS dla gier bez doskonałej informacji – wspólne drzewo

- ▶ każdy węzeł w drzewie T reprezentuje zbiór pozycji „nierozróżnialnych” z punktu widzenia gracza Max, przy tym:
- ▶ albo ruch we wszystkich pozycjach ze zbioru należy do Maxa i wtedy jest to zbiór informacyjny,
- ▶ albo ruch we wszystkich pozycjach ze zbioru należy do Mina i wtedy poszczególne pozycje mogą różnić się możliwymi do wykonania (przez Mina) ruchami,
- ▶ to z kolei wymusza modyfikacje MCTSa:
- ▶ na etapie selekcji trzeba ograniczyć wybór do zagrań dopuszczalnych w rozpatrywanej determinizacji,
- ▶ przeprowadzając ekspansję drzewa T , należy pamiętać o dodaniu następników niedostępnych w aktualnie rozpatrywanej determinizacji;
- ▶ w selekcji przez UCT, we wzorze na $f(x)$, liczbę n_w (liczba dotychczasowych rozgrywek, które przebiegły przez w – ojca węzła x), należy zastąpić liczbą dotychczasowych rozgrywek, które przebiegły przez w i w których ruch do x był dostępny.

MCTS dla gier bez doskonałej informacji – wspólne drzewo

- ▶ każdy węzeł w drzewie T reprezentuje zbiór pozycji „nierozróżnialnych” z punktu widzenia gracza Max, przy tym:
- ▶ albo ruch we wszystkich pozycjach ze zbioru należy do Maxa i wtedy jest to zbiór informacyjny,
- ▶ albo ruch we wszystkich pozycjach ze zbioru należy do Mina i wtedy poszczególne pozycje mogą różnić się możliwymi do wykonania (przez Mina) ruchami,
- ▶ to z kolei wymusza modyfikacje MCTSa:
- ▶ na etapie selekcji trzeba ograniczyć wybór do zagrań dopuszczalnych w rozpatrywanej determinizacji,
- ▶ przeprowadzając ekspansję drzewa T , należy pamiętać o dodaniu następników niedostępnych w aktualnie rozpatrywanej determinizacji;
- ▶ w selekcji przez UCT, we wzorze na $f(x)$, liczbę n_w (liczba dotychczasowych rozgrywek, które przebiegły przez w – ojca węzła x), należy zastąpić liczbą dotychczasowych rozgrywek, które przebiegły przez w i w których ruch do x był dostępny.

MCTS dla gier bez doskonałej informacji – wspólne drzewo

- ▶ każdy węzeł w drzewie T reprezentuje zbiór pozycji „nierozróżnialnych” z punktu widzenia gracza Max, przy tym:
- ▶ albo ruch we wszystkich pozycjach ze zbioru należy do Maxa i wtedy jest to zbiór informacyjny,
- ▶ albo ruch we wszystkich pozycjach ze zbioru należy do Mina i wtedy poszczególne pozycje mogą różnić się możliwymi do wykonania (przez Mina) ruchami,
- ▶ to z kolei wymusza modyfikacje MCTSa:
- ▶ na etapie selekcji trzeba ograniczyć wybór do zagrań dopuszczalnych w rozpatrywanej determinizacji,
- ▶ przeprowadzając ekspansję drzewa T , należy pamiętać o dodaniu następników niedostępnych w aktualnie rozpatrywanej determinizacji;
- ▶ w selekcji przez UCT, we wzorze na $f(x)$, liczbę n_w (liczba dotychczasowych rozgrywek, które przebiegły przez w – ojca węzła x), należy zastąpić liczbą dotychczasowych rozgrywek, które przebiegły przez w i w których ruch do x był dostępny.

Problem braku lokalności [Frank 1996]

- ▶ w grach z doskonałą informacją wartość pozycji zależy jedynie od podgrafu złożonego z węzłów z niej osiągalnych;
- ▶ w grach bez doskonałej informacji, analogiczne stwierdzenie nie jest prawdziwe;
- ▶ uczestnicy mogą wyciągać wnioski z zaobserwowanych wcześniej zagrań przeciwnika;
- ▶ istotne są nawet te części grafu gry, które nie zostały i nie mogą już zostać osiągnięte;
- ▶ rozwiązanie dla PIMC: ważenie poszczególnych determinizacji (względny) prawdopodobieństwami tego, że są one bieżącą pozycją w grze.

Problem braku lokalności [Frank 1996]

- ▶ w grach z doskonałą informacją wartość pozycji zależy jedynie od podgrafu złożonego z węzłów z niej osiągalnych;
- ▶ w grach bez doskonałej informacji, analogiczne stwierdzenie nie jest prawdziwe;
- ▶ uczestnicy mogą wyciągać wnioski z zaobserwowanych wcześniej zagrań przeciwnika;
- ▶ istotne są nawet te części grafu gry, które nie zostały i nie mogą już zostać osiągnięte;
- ▶ rozwiązanie dla PIMC: ważenie poszczególnych determinizacji (względny) prawdopodobieństwami tego, że są one bieżącą pozycją w grze.

Problem braku lokalności [Frank 1996]

- ▶ w grach z doskonałą informacją wartość pozycji zależy jedynie od podgrafu złożonego z węzłów z niej osiągalnych;
- ▶ w grach bez doskonałej informacji, analogiczne stwierdzenie nie jest prawdziwe;
- ▶ uczestnicy mogą wyciągać wnioski z zaobserwowanych wcześniej zagrań przeciwnika;
- ▶ istotne są nawet te części grafu gry, które nie zostały i nie mogą już zostać osiągnięte;
- ▶ rozwiązanie dla PIMC: ważenie poszczególnych determinizacji (względny) prawdopodobieństwami tego, że są one bieżącą pozycją w grze.

Problem braku lokalności [Frank 1996]

- ▶ w grach z doskonałą informacją wartość pozycji zależy jedynie od podgrafu złożonego z węzłów z niej osiągalnych;
- ▶ w grach bez doskonałej informacji, analogiczne stwierdzenie nie jest prawdziwe;
- ▶ uczestnicy mogą wyciągać wnioski z zaobserwowanych wcześniej zagrań przeciwnika;
- ▶ istotne są nawet te części grafu gry, które nie zostały i nie mogą już zostać osiągnięte;
- ▶ rozwiązanie dla PIMC: ważenie poszczególnych determinizacji (względny) prawdopodobieństwami tego, że są one bieżącą pozycją w grze.

Problem braku lokalności [Frank 1996]

- ▶ w grach z doskonałą informacją wartość pozycji zależy jedynie od podgrafu złożonego z węzłów z niej osiągalnych;
- ▶ w grach bez doskonałej informacji, analogiczne stwierdzenie nie jest prawdziwe;
- ▶ uczestnicy mogą wyciągać wnioski z zaobserwowanych wcześniej zagrań przeciwnika;
- ▶ istotne są nawet te części grafu gry, które nie zostały i nie mogą już zostać osiągnięte;
- ▶ rozwiązanie dla PIMC: ważenie poszczególnych determinizacji (względny) prawdopodobieństwami tego, że są one bieżącą pozycją w grze.

Algorytm szacujący względne prawdopodobieństwo $p(s)$ tego, że gra znajduje się w pozycji s [Beling doktorat]:

1. Zrekonstruuj ścieżkę, przebieg gry od jej początku, do pozycji s .
2. Dla wszystkich pozycji s_i ($i = 1, \dots, n$) na tej ścieżce, w których ruch należał do przeciwnika:
 - ▶ oszacuj $p_s(s_i)$ – prawdopodobieństwo, że gdyby gra była w pozycji s_i , to przeciwnik wykonałby ruch wzdłuż rozważanej ścieżki,
 - ▶ zakładając, że gra on poprawnie;
 - ▶ poprawność poszczególnych zagrań przybliż ich poprawnością w determinizacji s_i ;
 - ▶ użyj wspólnej tablicy transpozycji wykonując obliczenia dla $s_1, \dots, s_n$ (potem także dla s).
3. Oblicz $p(s) = p_s(s_1)p_s(s_2)\dots p_s(s_n)$.




Algorytm szacujący względne prawdopodobieństwo $p(s)$ tego, że gra znajduje się w pozycji s [Beling doktorat]:

1. Zrekonstruuuj ścieżkę, przebieg gry od jej początku, do pozycji s .
2. Dla wszystkich pozycji s_i ($i = 1, \dots, n$) na tej ścieżce, w których ruch należał do przeciwnika:
 - ▶ oszacuj $p_s(s_i)$ – prawdopodobieństwo, że gdyby gra była w pozycji s_i , to przeciwnik wykonałby ruch wzdłuż rozważanej ścieżki,
 - ▶ zakładając, że gra on poprawnie;
 - ▶ poprawność poszczególnych zagrań przybliż ich poprawnością w determinizacji s_i ;
 - ▶ użyj wspólnej tablicy transpozycji wykonując obliczenia dla $s_1, \dots, s_n$ (potem także dla s).
3. Oblicz $p(s) = p_s(s_1)p_s(s_2) \dots p_s(s_n)$.




Algorytm szacujący względne prawdopodobieństwo $p(s)$ tego, że gra znajduje się w pozycji s [Beling doktorat]:

1. Zrekonstruuuj ścieżkę, przebieg gry od jej początku, do pozycji s .
2. Dla wszystkich pozycji s_i ($i = 1, \dots, n$) na tej ścieżce, w których ruch należał do przeciwnika:
 - ▶ oszacuj $p_s(s_i)$ – prawdopodobieństwo, że gdyby gra była w pozycji s_i , to przeciwnik wykonałby ruch wzdłuż rozważanej ścieżki,
 - ▶ zakładając, że gra on poprawnie;
 - ▶ poprawność poszczególnych zagrań przybliż ich poprawnością w determinizacji s_i ;
 - ▶ użyj wspólnej tablicy transpozycji wykonując obliczenia dla $s_1, \dots, s_n$ (potem także dla s).
3. Oblicz $p(s) = p_s(s_1)p_s(s_2) \dots p_s(s_n)$.




Algorytm szacujący względne prawdopodobieństwo $p(s)$ tego, że gra znajduje się w pozycji s [Beling doktorat]:

1. Zrekonstruuj ścieżkę, przebieg gry od jej początku, do pozycji s .
2. Dla wszystkich pozycji s_i ($i = 1, \dots, n$) na tej ścieżce, w których ruch należał do przeciwnika:
 - ▶ oszacuj $p_s(s_i)$ – prawdopodobieństwo, że gdyby gra była w pozycji s_i , to przeciwnik wykonałby ruch wzdłuż rozważanej ścieżki,
 - ▶ zakładając, że gra on poprawnie;
 - ▶ poprawność poszczególnych zagrań przybliż ich poprawnością w determinizacji s_i ;
 - ▶ użyj wspólnej tablicy transpozycji wykonując obliczenia dla $s_1, \dots, s_n$ (potem także dla s).
3. Oblicz $p(s) = p_s(s_1)p_s(s_2) \dots p_s(s_n)$.




Algorytm szacujący względne prawdopodobieństwo $p(s)$ tego, że gra znajduje się w pozycji s [Beling doktorat]:

1. Zrekonstruuj ścieżkę, przebieg gry od jej początku, do pozycji s .
2. Dla wszystkich pozycji s_i ($i = 1, \dots, n$) na tej ścieżce, w których ruch należał do przeciwnika:
 - ▶ oszacuj $p_s(s_i)$ – prawdopodobieństwo, że gdyby gra była w pozycji s_i , to przeciwnik wykonałby ruch wzdłuż rozważanej ścieżki,
 - ▶ zakładając, że gra on poprawnie;
 - ▶ poprawność poszczególnych zagrań przybliż ich poprawnością w determinizacji s_i ;
 - ▶ użyj wspólnej tablicy transpozycji wykonując obliczenia dla $s_1, \dots, s_n$ (potem także dla s).
3. Oblicz $p(s) = p_s(s_1)p_s(s_2) \dots p_s(s_n)$.




Algorytm szacujący względne prawdopodobieństwo $p(s)$ tego, że gra znajduje się w pozycji s [Beling doktorat]:

1. Zrekonstruuj ścieżkę, przebieg gry od jej początku, do pozycji s .
2. Dla wszystkich pozycji s_i ($i = 1, \dots, n$) na tej ścieżce, w których ruch należał do przeciwnika:
 - ▶ oszacuj $p_s(s_i)$ – prawdopodobieństwo, że gdyby gra była w pozycji s_i , to przeciwnik wykonałby ruch wzdłuż rozważanej ścieżki,
 - ▶ zakładając, że gra on poprawnie;
 - ▶ poprawność poszczególnych zagrań przybliż ich poprawnością w determinizacji s_i ;
 - ▶ użyj wspólnej tablicy transpozycji wykonując obliczenia dla $s_1, \dots, s_n$ (potem także dla s).
3. Oblicz $p(s) = p_s(s_1)p_s(s_2) \dots p_s(s_n)$.




Algorytm szacujący względne prawdopodobieństwo $p(s)$ tego, że gra znajduje się w pozycji s [Beling doktorat]:

1. Zrekonstruuuj ścieżkę, przebieg gry od jej początku, do pozycji s .
2. Dla wszystkich pozycji s_i ($i = 1, \dots, n$) na tej ścieżce, w których ruch należał do przeciwnika:
 - ▶ oszacuj $p_s(s_i)$ – prawdopodobieństwo, że gdyby gra była w pozycji s_i , to przeciwnik wykonałby ruch wzdłuż rozważanej ścieżki,
 - ▶ zakładając, że gra on poprawnie;
 - ▶ poprawność poszczególnych zagrań przybliż ich poprawnością w determinizacji s_i ;
 - ▶ użyj wspólnej tablicy transpozycji wykonując obliczenia dla $s_1, \dots, s_n$ (potem także dla s).
3. Oblicz $p(s) = p_s(s_1)p_s(s_2) \dots p_s(s_n)$.



Algorytm szacujący względne prawdopodobieństwo $p(s)$ tego, że gra znajduje się w pozycji s [Beling doktorat]:

1. Zrekonstruuuj ścieżkę, przebieg gry od jej początku, do pozycji s .
2. Dla wszystkich pozycji s_i ($i = 1, \dots, n$) na tej ścieżce, w których ruch należał do przeciwnika:
 - ▶ oszacuj $p_s(s_i)$ – prawdopodobieństwo, że gdyby gra była w pozycji s_i , to przeciwnik wykonałby ruch wzdłuż rozważanej ścieżki,
 - ▶ zakładając, że gra on poprawnie;
 - ▶ poprawność poszczególnych zagrań przybliż ich poprawnością w determinizacji s_i ;
 - ▶ użyj wspólnej tablicy transpozycji wykonując obliczenia dla $s_1, \dots, s_n$ (potem także dla s).
3. Oblicz $p(s) = p_s(s_1)p_s(s_2) \dots p_s(s_n)$.



$$p(s) = 50\% \cdot 30\% \cdot 60\% \\ = 9\%$$

Bibliografia

- ▶ **Louis V. Allis** *Searching for Solutions in Games and Artificial Intelligence*, rozprawa doktorska, 1994
- ▶ **H. Jaap van den Herik, et al.** *Games solved: Now and in the future*, Artificial Intelligence 134/2002
- ▶ **Donald E. Knuth, Ronald W. Moore** *An Analysis of Alpha-Beta Pruning*, Artificial Intelligence 6/1975
- ▶ **L. Kocsis, C. Szepesvári** *Bandit Based Monte-carlo Planning*, Proceedings of the 17th European Conference on Machine Learning, ECML'06, 2006
- ▶ **C. Browne, et al.** *A Survey of Monte Carlo Tree Search Methods*, IEEE Transactions on Computational Intelligence and AI in Games, 2012, Volume 4, Issue 1
- ▶ **P. Beling** *Szybkie algorytmy decyzyjne w grach z doskonałą informacją i ich wykorzystanie w grach jej pozbawionych*, rozprawa doktorska, Uniwersytet Łódzki, 2016
- ▶ **I. Frank** *Search and Planning under Incomplete Information - A Study using Bridge Card Play* rozprawa doktorska, The University of Edinburgh, 1996

Dziękuję za uwagę!

