

Rozwiązywanie zadań
przez przeszukiwanie
 A^* , najszybszy wzrost, metoda Newtona

Jarosław Arabas

jaroslaw.arabas@pw.edu.pl
pok. 23


Artificial Intelligence

Dartmouth Summer Research Project
on Artificial Intelligence 1956



acting
reasonably

acting
like humans



thinking
reasonably

thinking
like humans



(wg Russell, Norvig)

Słaba sztuczna inteligencja

Objaśnianie zjawisk
Przewidywanie zjawisk
Analiza scenariuszy

**Uczenie
maszynowe**

Tryb doradczy
Tryb autonomiczny

**Podejmowanie
decyzji**

O co chodzi w AI?



- uczenie z danych
- wspomaganie decyzji



- działanie nieodróżnialne od ludzkiego

O co chodzi w AI?



Dyskryminacyjna AI



Generatywna AI

Uczenie maszynowe

dane

```
1, 273, 82, 105, 210, 9, 904, 680, 23, 62, 34.99
2, 163, 149, 191, 180, 12, 843, 746, 0, 20, 41.14
3, 162, 148, 191, 179, 16, 840, 743, 1, 20, 41.81
4, 162, 148, 190, 179, 19, 838, 741, 3, 21.5, 42.08
5, 154, 112, 144, 220, 10, 923, 658, 20, 64, 26.82
6, 147, 89, 115, 202, 9, 860, 829, 23, 55, 25.21
7, 152, 139, 178, 168, 18, 944, 695, 0, 20, 38.86
8, 145, 0, 227, 240, 6, 750, 853, 14.5, 58.5, 36.59
9, 152, 0, 237, 204, 6, 785, 892, 15.5, 51, 32.71
10, 304, 0, 140, 214, 6, 895, 722, 19, 51, 38.46
11, 145, 106, 136, 208, 10, 751, 883, 24.5, 61, 26.02
12, 148, 109, 139, 193, 7, 768, 902, 23.75, 58, 28.03
13, 142, 130, 167, 215, 6, 735, 836, 25.5, 67, 31.37
14, 354, 0, 0, 234, 6, 959, 691, 17, 54, 33.91
15, 374, 0, 0, 190, 7, 1013, 730, 14.5, 42.5, 32.44
16, 159, 116, 149, 175, 15, 953, 720, 23.5, 54.5, 34.05
17, 153, 0, 239, 200, 6, 1002, 684, 12, 35, 28.29
18, 295, 106, 136, 206, 11, 750, 766, 25, 68.5, 41.01
19, 310, 0, 143, 168, 10, 914, 804, 20.5, 48.2, 49.3
20, 296, 97, 0, 219, 9, 932, 685, 15, 48.5, 29.23
21, 305, 100, 0, 196, 10, 959, 705, 20, 49, 29.77
22, 310, 0, 143, 218, 10, 787, 804, 13, 46, 36.19
23, 148, 180, 0, 183, 11, 972, 757, 0, 20, 18.52
24, 146, 178, 0, 192, 11, 961, 749, 18, 46, 17.19
25, 142, 130, 167, 174, 11, 883, 785, 0, 20, 36.72
26, 140, 128, 164, 183, 12, 871, 775, 23.75, 53, 33.38
27, 308, 111, 142, 217, 10, 783, 686, 25, 70, 42.08
28, 295, 106, 136, 208, 6, 871, 650, 26.5, 70, 39.4
29, 298, 107, 137, 201, 6, 878, 655, 16, 26, 41.27
30, 314, 0, 161, 207, 6, 851, 757, 21.5, 64, 41.14
31, 321, 0, 164, 190, 5, 870, 774, 24, 60, 45.82
32, 349, 0, 178, 230, 6, 785, 721, 20, 68.5, 43.95
33, 366, 0, 187, 191, 7, 824, 757, 24.75, 62.7, 52.65
34, 274, 89, 115, 202, 9, 759, 827, 26.5, 68, 35.52
35, 137, 167, 214, 226, 6, 708, 757, 27.5, 70, 34.45
36, 275, 99, 127, 184, 13, 810, 790, 25.75, 64.5, 43.54
37, 252, 76, 97, 194, 8, 835, 821, 23, 54, 33.11
38, 165, 150, 0, 182, 12, 1023, 729, 14.5, 20, 18.26
39, 158, 0, 246, 174, 7, 1035, 706, 19, 43, 34.99
40, 156, 0, 243, 180, 11, 1022, 698, 21, 57, 33.78
41, 145, 177, 227, 209, 11, 752, 715, 2.5, 20, 35.66
42, 154, 141, 181, 234, 11, 797, 683, 23, 65, 33.51
43, 160, 146, 188, 203, 11, 829, 710, 13, 38, 33.51
44, 291, 105, 0, 205, 6, 859, 797, 24, 59, 27.62
45, 298, 107, 0, 186, 6, 879, 815, 3, 20, 30.97
46, 318, 126, 0, 210, 6, 861, 737, 17.5, 48, 31.77
47, 280, 92, 118, 207, 9, 883, 679, 25.5, 64, 37.39
```

atrybuty
wejściowe



atrybut
wyjściowy

- Model ma agregować dane i przewidywać nieznane
- Milczące założenie:
zależności obecne w danych
będą zachodzić w przyszłości

Uczenie maszynowe

dane

1, 273, 82, 105, 210, 9, 904, 680, 23, 62, 34. 99
2, 163, 149, 191, 180, 12, 843, 746, 0, 20, 41. 14
3, 162, 148, 191, 179, 16, 840, 743, 1, 20, 41. 81
4, 162, 148, 190, 179, 19, 838, 741, 3, 21. 5, 42. 08
5, 154, 112, 144, 220, 10, 923, 658, 20, 64, 26. 82
6, 147, 89, 115, 202, 9, 860, 829, 23, 55, 25. 21
7, 152, 139, 178, 168, 18, 944, 695, 0, 20, 38. 86
8, 145, 0, 227, 240, 6, 750, 853, 14. 5, 58. 5, 36. 59
9, 152, 0, 237, 204, 6, 785, 892, 15. 5, 51, 32. 71
10, 304, 0, 140, 214, 6, 895, 722, 19, 51, 38. 46
11, 145, 106, 136, 208, 10, 751, 883, 24. 5, 61, 26. 02
12, 148, 109, 139, 193, 7, 768, 902, 23. 75, 58, 28. 03
13, 142, 130, 167, 215, 6, 735, 836, 25. 5, 67, 31. 37
14, 354, 0, 0, 234, 6, 959, 691, 17, 54, 33. 91
15, 374, 0, 0, 190, 7, 1013, 730, 14. 5, 42. 5, 32. 44
16, 159, 116, 149, 175, 15, 953, 720, 23. 5, 54. 5, 34. 05
17, 153, 0, 239, 200, 6, 1002, 684, 12, 35, 28. 29
18, 295, 106, 136, 206, 11, 750, 766, 25, 68. 5, 41. 01
19, 310, 0, 143, 168, 10, 914, 804, 20. 5, 48. 2, 49. 3
20, 296, 97, 0, 219, 9, 932, 685, 15, 48. 5, 29. 23
21, 305, 100, 0, 196, 10, 959, 705, 20, 49, 29. 77
22, 310, 0, 143, 218, 10, 787, 804, 13, 46, 36. 19
23, 148, 180, 0, 183, 11, 972, 757, 0, 20, 18. 52
24, 146, 178, 0, 192, 11, 961, 749, 18, 46, 17. 19
25, 142, 130, 167, 174, 11, 883, 785, 0, 20, 36. 72
26, 140, 128, 164, 183, 12, 871, 775, 23. 75, 53, 33. 38
27, 308, 111, 142, 217, 10, 783, 686, 25, 70, 42. 08
28, 295, 106, 136, 208, 6, 871, 650, 26. 5, 70, 39. 4
29, 298, 107, 137, 201, 6, 878, 655, 16, 26, 41. 27
30, 314, 0, 161, 207, 6, 851, 757, 21. 5, 64, 41. 14
31, 321, 0, 164, 190, 5, 870, 774, 24, 60, 45. 82
32, 349, 0, 178, 230, 6, 785, 721, 20, 68. 5, 43. 95
33, 366, 0, 187, 191, 7, 824, 757, 24. 75, 62. 7, 52. 65
34, 274, 89, 115, 202, 9, 759, 827, 26. 5, 68, 35. 52
35, 137, 167, 214, 226, 6, 708, 757, 27. 5, 70, 34. 45
36, 275, 99, 127, 184, 13, 810, 790, 25. 75, 64. 5, 43. 54
37, 252, 76, 97, 194, 8, 835, 821, 23, 54, 33. 11
38, 165, 150, 0, 182, 12, 1023, 729, 14. 5, 20, 18. 26
39, 158, 0, 246, 174, 7, 1035, 706, 19, 43, 34. 99
40, 156, 0, 243, 180, 11, 1022, 698, 21, 57, 33. 78
41, 145, 177, 227, 209, 11, 752, 715, 2. 5, 20, 35. 66
42, 154, 141, 181, 234, 11, 797, 683, 23, 65, 33. 51
43, 160, 146, 188, 203, 11, 829, 710, 13, 38, 33. 51
44, 291, 105, 0, 205, 6, 859, 797, 24, 59, 27. 62
45, 298, 107, 0, 186, 6, 879, 815, 3, 20, 30. 97
46, 318, 126, 0, 210, 6, 861, 737, 17. 5, 48, 31. 77
47, 280, 92, 118, 207, 9, 883, 679, 25. 5, 64, 37. 39


atrybuty
wejściowe



nieznana
zależność

atrybut
wyjściowy

atrybuty
wejściowe



model

atrybut
wyjściowy

Uczenie maszynowe

dane

1, 273, 82, 105, 210, 9, 904, 680, 23, 62, 34.99
2, 163, 149, 191, 180, 12, 843, 746, 0, 20, 41.14
3, 162, 148, 191, 179, 16, 840, 743, 1, 20, 41.81
4, 162, 148, 190, 179, 19, 838, 741, 3, 21.5, 42.08
5, 154, 112, 144, 220, 10, 923, 658, 20, 64, 26.82
6, 147, 89, 115, 202, 9, 860, 829, 23, 55, 25.21
7, 152, 139, 178, 168, 18, 944, 695, 0, 20, 38.86
8, 145, 0, 227, 240, 6, 750, 853, 14.5, 58.5, 36.59
9, 152, 0, 237, 204, 6, 785, 892, 15.5, 51, 32.71
10, 304, 0, 140, 214, 6, 895, 722, 19, 51, 38.46
11, 145, 106, 136, 208, 10, 751, 883, 24.5, 61, 26.02
12, 148, 109, 139, 193, 7, 768, 902, 23.75, 58, 28.03
13, 142, 130, 167, 215, 6, 735, 836, 25.5, 67, 31.37
14, 354, 0, 0, 234, 6, 959, 691, 17, 54, 33.91
15, 374, 0, 0, 190, 7, 1013, 730, 14.5, 42.5, 32.44
16, 159, 116, 149, 175, 15, 953, 720, 23.5, 54.5, 34.05
17, 153, 0, 239, 200, 6, 1002, 684, 12, 35, 28.29
18, 295, 106, 136, 206, 11, 750, 766, 25, 68.5, 41.01
19, 310, 0, 143, 168, 10, 914, 804, 20.5, 48.2, 49.3
20, 296, 97, 0, 219, 9, 932, 685, 15, 48.5, 29.23
21, 305, 100, 0, 196, 10, 959, 705, 20, 49, 29.77
22, 310, 0, 143, 218, 10, 787, 804, 13, 46, 36.19
23, 148, 180, 0, 183, 11, 972, 757, 0, 20, 18.52
24, 146, 178, 0, 192, 11, 961, 749, 18, 46, 17.19
25, 142, 130, 167, 174, 11, 883, 785, 0, 20, 36.72
26, 140, 128, 164, 183, 12, 871, 775, 23.75, 53, 33.38
27, 308, 111, 142, 217, 10, 783, 686, 25, 70, 42.08
28, 295, 106, 136, 208, 6, 871, 650, 26.5, 70, 39.4
29, 298, 107, 137, 201, 6, 878, 655, 16, 26, 41.27
30, 314, 0, 161, 207, 6, 851, 757, 21.5, 64, 41.14
31, 321, 0, 164, 190, 5, 870, 774, 24, 60, 45.82
32, 349, 0, 178, 230, 6, 785, 721, 20, 68.5, 43.95
33, 366, 0, 187, 191, 7, 824, 757, 24.75, 62.7, 52.65
34, 274, 89, 115, 202, 9, 759, 827, 26.5, 68, 35.52
35, 137, 167, 214, 226, 6, 708, 757, 27.5, 70, 34.45
36, 275, 99, 127, 184, 13, 810, 790, 25.75, 64.5, 43.54
37, 252, 76, 97, 194, 8, 835, 821, 23, 54, 33.11
38, 165, 150, 0, 182, 12, 1023, 729, 14.5, 20, 18.26
39, 158, 0, 246, 174, 7, 1035, 706, 19, 43, 34.99
40, 156, 0, 243, 180, 11, 1022, 698, 21, 57, 33.78
41, 145, 177, 227, 209, 11, 752, 715, 2.5, 20, 35.66
42, 154, 141, 181, 234, 11, 797, 683, 23, 65, 33.51
43, 160, 146, 188, 203, 11, 829, 710, 13, 38, 33.51
44, 291, 105, 0, 205, 6, 859, 797, 24, 59, 27.62
45, 298, 107, 0, 186, 6, 879, 815, 3, 20, 30.97
46, 318, 126, 0, 210, 6, 861, 737, 17.5, 48, 31.77
47, 280, 92, 118, 207, 9, 883, 679, 25.5, 64, 37.39



**Dane są
zasobem krytycznym**

Uczenie maszynowe – czego dotyczy

Uczenie z danych o różnym poziomie “obiektywności”

Uczenie maszynowe – czego dotyczy

Uczenie z danych o różnym poziomie “obiektywności”

- ◉ Pomiarowych, opisujących świat “nieożywiony”



Uczenie maszynowe – czego dotyczy

Uczenie z danych o różnym poziomie “obiektywności”

- ◉ Pomiarowych, opisujących świat “nieożywiony”
- ◉ Pomiarowych, opisujących interakcję człowieka ze światem




Uczenie maszynowe – czego dotyczy

Uczenie z danych o różnym poziomie “obiektywności”

- ◉ Pomiarowych, opisujących świat “nieożywiony”
- ◉ Pomiarowych, opisujących interakcję człowieka ze światem
- ◉ Wytworzonych przez człowieka tekstów i obrazów



Uczenie maszynowe – czego dotyczy



Uczenie z danych o różnym poziomie “obiektywności”

- ◉ Pomiarowych, opisujących świat “nieożywiony”
- ◉ Pomiarowych, opisujących interakcję człowieka ze światem
- ◉ Wytworzonych przez człowieka tekstów i obrazów



**Narastające trudności
z weryfikacją sukcesu**

Podjmowanie decyzji

Przykład: problem plecakowy

- n przedmiotów
- Każdy przedmiot ma wagę $w_i > 0$ i wartość $p_i > 0$
- Wybrać przedmioty o największej łącznej wartości i łącznej wadze nie większej niż W

$$\begin{aligned} \max \quad & \sum_{i=1}^n x_i p_i \\ \sum_{i=1}^n x_i w_i & \leq W \\ x_i & \in \{0, 1\} \end{aligned}$$

Problem plecakowy

- n przedmiotów
- Każdy przedmiot ma wagę $w_i > 0$ i wartość $p_i > 0$
- Wybrać przedmioty o największej łącznej wartości i łącznej wadze nie większej niż W



$$\begin{aligned} \max \quad & \sum_{i=1}^n x_i p_i \\ \text{s.t.} \quad & \sum_{i=1}^n x_i w_i \leq W \\ & x_i \in \{0, 1\} \end{aligned}$$



Problem plecakowy – przykład

- Przedmioty

i	1	2	3	4
p _i	16	8	9	6
w _i	8	3	5	2
p _i /w _i	2	2.66	1.8	3

- W=9

$$\max \sum_{i=1}^n x_i p_i$$

$$\sum_{i=1}^n x_i w_i \leq W$$

$$x_i \in \{0,1\}$$

Problem plecakowy – przykład


- Przedmioty

i	1	2	3	4
p_i	16	8	9	6
w_i	8	3	5	2
p_i/w_i	2	2.66	1.8	3

- $W=9$

0000	0001	0010	0011	0100	0101	0110	0111	1000	1001	1010	1011	1100	1101	1110	1111
0	6	9	15	8	14	17	23	16	22	25	31	24	30	33	39
0	2	5	7	3	5	8	10	8	10	13	13	11	13	16	18

Przestrzeń przeszukiwań



Algorytm wspinaczkowy

algorytm wspinaczkowy

$x \leftarrow x_0$

while ! stop

$Y \leftarrow N(x)$


$y \leftarrow \text{wybierzNajlepszego}(Y)$

if $q(y) > q(x)$


$x \leftarrow y$

x – punkt roboczy


Algorytm wspinaczkowy



Algorytm wspinaczkowy



Algorytm wspinaczkowy



W $\mathbb{R}^n$ jest
continuum sąsiadów

Nie da się
wszystkich zbadać

Metoda najszybszego wzrostu *steepest ascent, gradient ascent*

algorytm **największego wzrostu**

$\mathbf{x} \leftarrow \mathbf{x}_0$

while ! stop

$\mathbf{d} \leftarrow \nabla q(\mathbf{x})$

$\mathbf{x} \leftarrow \mathbf{x} + \beta_t \mathbf{d}$

$\mathbf{x}$ – punkt roboczy

$\nabla q(\mathbf{x})$ Gradient funkcji celu w punkcie $\mathbf{x}$
 β_t Ciąg dodatnich współczynników kroku

$$\nabla q(\mathbf{x}) = \begin{bmatrix} \partial q(\mathbf{x}) / \partial x_1 \\ \vdots \\ \partial q(\mathbf{x}) / \partial x_i \\ \vdots \\ \partial q(\mathbf{x}) / \partial x_n \end{bmatrix}$$

Metoda najszybszego wzrostu *steepest ascent, gradient ascent*

algorytm *największego wzrostu*

$x \leftarrow x_0$





while ! stop

$d \leftarrow \nabla q(x)$

$x \leftarrow x + \beta_t d$

W praktyce gradient jest
estymowany np. przez
losowe próbkowanie

Wówczas mówimy
o stochastycznym najszybszym
wzroście/spadku



Metoda Newtona

algorytm metoda Newtona

$\mathbf{x} \leftarrow \mathbf{x}_0$

while ! stop

$\mathbf{x}$ – punkt roboczy

$\mathbf{d} \leftarrow H_q^{-1}(\mathbf{x}) \cdot \nabla q(\mathbf{x})$

$\mathbf{x} \leftarrow \mathbf{x} + \beta \mathbf{d}$

$H_q(\mathbf{x})$ hesjan funkcji celu w punkcie $\mathbf{x}$

$$H_q(\mathbf{x}) = \begin{bmatrix} \partial^2 q(\mathbf{x}) / (\partial x_1)^2 & \partial^2 q(\mathbf{x}) / (\partial x_1 \cdot \partial x_2) & \cdots \\ \partial^2 q(\mathbf{x}) / (\partial x_1 \cdot \partial x_2) & \partial^2 q(\mathbf{x}) / (\partial x_2)^2 & \cdots \\ \vdots & \vdots & \ddots \end{bmatrix}$$

W praktyce hesjan jest aproksymowany – metody BFGS, DFP
zwane metodami zmiennej metryki

Metoda Newtona

algorytm *największego wzrostu*

$\mathbf{x} \leftarrow \mathbf{x}_0$

while ! stop

$\mathbf{d} \leftarrow \nabla q(\mathbf{x})$

$\mathbf{x} \leftarrow \mathbf{x} + \beta \mathbf{d}$



algorytm *metoda Newtona*

$\mathbf{x} \leftarrow \mathbf{x}_0$

while ! stop

$\mathbf{d} \leftarrow H_q^{-1}(\mathbf{x}) \cdot \nabla q(\mathbf{x})$

$\mathbf{x} \leftarrow \mathbf{x} + \beta \mathbf{d}$



Problem plecakowy


- n przedmiotów
- Każdy przedmiot ma wagę $w_i > 0$ i wartość $p_i > 0$
- Wybrać przedmioty o największej łącznej wartości i łącznej wadze nie większej niż W



$$\begin{aligned} \max \quad & \sum_{i=1}^n x_i p_i \\ \sum_{i=1}^n x_i w_i & \leq W \\ x_i & \in \{0, 1\} \end{aligned}$$




Przestrzeń przeszukiwań




Popatrzmy
z innej
perspektywy...


Przestrzeń przeszukiwań




Przestrzeń przeszukiwań




Przestrzeń przeszukiwań




Przestrzeń przeszukiwań




Funkcja celu, zbiór dopuszczalny



Propagacja wartości f.celu “od tyłu”



Rady Dobrej Wróżki



Algorytm najpierw najlepszy

algorytm najpierw najlepszy

$A \leftarrow \text{init}(s_0)$

while ! stop


$x \leftarrow \text{popPriorityQueue}(A)$

$Y \leftarrow \text{dzieci}(x)$


$A \leftarrow A \cup Y$

- Jeśli etykiety są dokładne, to możemy algorytm zatrzymać po dotarciu do pierwszego terminalnego wężła

Jak uzyskać rady Dobrej Wróżki?



Rady niedobrej wróżki



Algorytm najpierw najlepszy

algorytm najpierw najlepszy

$A \leftarrow \text{init}(s_0)$

while ! stop

$x \leftarrow \text{popPriorityQueue}(A)$

$Y \leftarrow \text{dzieci}(x)$

$A \leftarrow A \cup Y$

- Jeśli etykiety są niedokładne, to algorytm musi wyczerpać listę A aby dać gwarancję uzyskania wyniku optymalnego

WANTED



an oracle

Funkcja heurystyczna (dla problemu maksymalizacji)

- Dla problemu plecakowego, ostateczny zysk jest sumą zysków dających się wyznaczyć niezależnie dla każdej decyzji

$$g(\mathbf{x}) = g_1(x_1) + g_2(x_2) + \dots + g_n(x_n)$$

- Można dokonać oszacowania dla sekwencji k podjętych decyzji ('?' oznacza niepodjętą decyzję):

$$g(x_1 \dots x_k, ?_{k+1} \dots ?_n) \geq \sum_{i=1 \dots k} g_i(x_i)$$

$$g(x_1 \dots x_k, ?_{k+1} \dots ?_n) \leq \sum_{i=1 \dots k} g_i(x_i) + \sum_{i=k+1 \dots n} \max_{y_i} g_i(y_i)$$

To górne ograniczenie jest niedokładne, spróbujmy je poprawić

Funkcja heurystyczna

- Idealne górne oszacowanie przyrostu zysku dla niepodjętych decyzji (F jest zbiorem dopuszczalnych liści)

$$g(x_1 \dots x_k, ?_{k+1} \dots ?_n) \leq \sum_{i=1 \dots k} g_i(x_i) + \max_{y: x_1 \dots x_k, y_{k+1} \dots y_n \in F} \sum_{i=k+1 \dots n} g_i(y_i)$$

- Funkcja heurystyczna h jest oszacowaniem nieidealnym:

$$g(x_1 \dots x_k, ?_{k+1} \dots ?_n) \leq \sum_{i=1 \dots k} g_i(x_i) + h(x_1 \dots x_k, ?_{k+1} \dots ?_n)$$

- Powinna być dopuszczalna


$$h(x_1 \dots x_k, ?_{k+1} \dots ?_n) \geq \max_{y: x_1 \dots x_k, y_{k+1} \dots y_n \in F} \sum_{i=k+1 \dots n} g_i(y_i)$$

- Powinna być monotoniczna

$$\sum_{i=1 \dots k+1} g_i(x_i) + h(x_1 \dots x_{k+1}, ?_{k+2} \dots ?_n) \leq \sum_{i=1 \dots k+1} g_i(x_i) + h(x_1 \dots x_k, ?_{k+1} \dots ?_n)$$

Kierunki nierówności są przyjęte dla zadania maksymalizacji, przy minimalizacji przyjmą przeciwne

Funkcja heurystyczna (dla problemu maksymalizacji)



Nadmierny optymizm

Błąd oszacowania malejący wraz
ze zbliżaniem się do rozwiązania

dopuszczalność: $g(x)+h(x) \geq g(x_t)$

monotoniczność: $g(x_j)+h(x_j) \leq g(x_i)+h(x_i)$

Algorytm A*

$$\begin{aligned} &\text{Algorytm najpierw najlepszy} \\ &+ \\ &\text{Funkcja kosztu} \\ &+ \\ &\text{Funkcja heurystyczna} \\ &= \\ &\text{Algorytm A*} \end{aligned}$$

Problem plecakowy

funkcja heurystyczna

- Przedmioty

i	1	2	3	4
p_i	6	8	9	16
w_i	2	3	5	8
p_i/w_i	3	2.66	1.8	2

- $W=9$

- Przykładowe rozwiązanie $x=1 \ ? \ ? \ ?$

- Łączna wartość:

$$g(x) = p_1 = 6$$

- Łączna waga:

$$w(x) = w_1 = 2$$

- Podziały przedmiotów:


$$y = [0, 1, 0, 1/2]$$

- Funkcja heurystyczna:

$$h(x) = 16 \cdot 1/2 + 8 \cdot 1 = 16$$


Problem plecakowy

funkcja zysku i funkcja heurystyczna



Problem plecakowy

funkcja zysku i funkcja heurystyczna



Algorytm najpierw najlepszy

algorytm najpierw najlepszy

$A \leftarrow \text{init}(s_0)$

$best \leftarrow 0$

while ! stop

$x \leftarrow \text{popPriorityQueue}(A)$

if $\text{terminal}(x) \wedge (g(x) > best)$

$best \leftarrow g(x)$

if ! $\text{terminal}(x) \wedge (g(x) + h(x) \geq best)$


$Y \leftarrow \text{dzieci}(x)$

$A \leftarrow A \cup Y$

- Jeśli funkcja heurystyczna jest dopuszczalna i monotoniczna, to można zmniejszyć liczbę rozwijanych węzłów
- Algorytm musi wyczerpać listę A aby dać gwarancję uzyskania wyniku optymalnego


Algorytm A*

$$\begin{aligned} &\text{Algorytm najpierw najlepszy} \\ &+ \\ &\text{Funkcja kosztu} \\ &+ \\ &\text{Funkcja heurystyczna} \\ &= \\ &\text{Algorytm A*} \end{aligned}$$




Find the shortest path from Gd to Kr

Gdańsk – old port




Kraków – market square

Search tree (a fragment)



Heuristic function – walking distance



Search tree (a fragment)

