

WYKŁAD 2

Reprezentacja wiedzy:



Sieci neuronowe

Drzewa decyzyjne

PLAN WYKŁADU


- Przypomnienie modelu perceptronu
- Przykładowe struktury wielowarstwowe
- Przykłady drzew decyzyjnych
- Drzewa decyzyjne a sieci neuronowe
 - Porównanie strukturalne
 - Porównanie funkcjonalne
 - Przejawy hybrydizacji

PERCEPTRON (PRZYPOMNIENIE)




PERCEPTRON (PRZYPOMNIENIE)

- Równanie perceptronu można potraktować jako równanie prostej (ogólnie: hiperpłaszczyzny w przestrzeni n-wymiarowej).
- Punkty leżące nad ową prostą klasyfikujemy jako 1, zaś pozostałe jako 0.





PERCEPTRON (PRZYPOMNIENIE)


- Pojedynczy perceptron nie potrafi odróżniać zbiorów nieseparowalnych liniowo, np. funkcji XOR.
- Odkrycie tych ograniczeń (1969) na wiele lat zahamowało rozwój sieci neuronowych.



PERCEPTRON (PRZYPOMNIENIE)




SIECI JAKO UKŁADY PERCEPTRONÓW



Ograniczenia pojedynczych perceptronów spowodowały w latach 80-tych wzrost zainteresowania sieciami wielowarstwowymi i opracowanie algorytmu ich uczenia (propagacja wsteczna)


SIECI PERCEPTRONÓW

Potrafiają reprezentować dowolną funkcję boolowską (opartą na rachunku zdań)




SIECI PERCEPTRONÓW

Potrafia modelować (dowolnie dokładnie przybliżać) funkcje rzeczywiste




$$y = f\left(w_0 + \sum_{i=1}^n w_i x_i\right)$$



$$f(z) = \frac{1}{1 + e^{-z}}$$



SIECI PERCEPTRONÓW




SIECI PERCEPTRONÓW




SIECI PERCEPTRONÓW

Potrafia klasyfikować obiekty na zasadzie „czarnej skrzynki”




DRZEWA DECYZYJNE

- Sieci neuronowe nie są jedynym narzędziem reprezentacji zależności
- Dobór narzędzia zależy od wymogów danego zastosowania
- Do innych narzędzi należą na przykład metody symboliczne, oparte na regułach bądź drzewach decyzyjnych




DRZEWA DECYZYJNE

	Outlook	Temp.	Humid.	Wind	Sport?
1	Sunny	Hot	High	Weak	No
2	Sunny	Hot	High	Strong	No
3	Overcast	Hot	High	Weak	Yes
4	Rain	Mild	High	Weak	Yes
5	Rain	Cold	Normal	Weak	Yes
6	Rain	Cold	Normal	Strong	No
7	Overcast	Cold	Normal	Strong	Yes
8	Sunny	Mild	High	Weak	No
9	Sunny	Cold	Normal	Weak	Yes
10	Rain	Mild	Normal	Weak	Yes
11	Sunny	Mild	Normal	Strong	Yes
12	Overcast	Mild	High	Strong	Yes
13	Overcast	Hot	Normal	Weak	Yes
14	Rain	Mild	High	Strong	No




DRZEWA DECYZYJNE

	Sun (%)	Temp. (°C)	Humid. (%)	Wind (km/h)	Run (km/h)
1	100	31	90	10	6
2	90	22	85	50	8
3	50	25	95	20	12
4	0	15	80	0	13
5	10	4	70	10	15
6	30	7	55	40	7
7	40	8	65	60	15
8	70	14	90	20	10
9	80	1	70	30	14
10	20	13	60	0	14
11	80	11	60	70	14
12	60	17	80	50	13
13	50	26	55	30	16
14	20	12	95	60	9



DRZEW A SIECI NEURONOWE

	Sun (%)	Temp. (°C)	Humid. (%)	Wind (km/h)	Run (km/h)
1	100	31	90	10	6
2	90	22	85	50	8
3	50	25	95	20	12
4	0	15	80	0	13
5	10	4	70	10	15
6	30	7	55	40	7
7	40	8	65	60	15
8	70	14	90	20	10
9	80	1	70	30	14
10	20	13	60	0	14
11	80	11	60	70	14
12	60	17	80	50	13
13	50	26	55	30	16
14	20	12	95	60	9



Można szukać sieci, która w warstwie wejściowej pobiera wartości zmiennych **Sun, Temp, Humid, Wind**, zaś na wyjściu stara się przyjmować stosowne wartości zmiennej **Run**

DRZEWA A SIECI NEURONOWE

- Drzewa decyzyjne:
 - Reprezentują zależności logiczne
 - Zdania wiązane tymi zależnościami mogą dotyczyć zarówno zmiennych symbolicznych jak i numerycznych
- Sieci neuronowe:
 - Reprezentują zależności numeryczne
 - Nawet w przypadku opisu powiązań symbolicznych, trzeba je przedstawić w formie funkcji rzeczywistych

DRZEWA A SIECI NEURONOWE

- Drzewa decyzyjne:
 - Mają przejrzystą strukturę
 - Nie nadają się jednak do dokładnej reprezentacji zależności funkcyjnych
- Sieci neuronowe:
 - Doskonałe dla wyrażania zależności funkcyjnych pomiędzy rzeczywistymi zmiennymi wejściowymi i wyjściowymi
 - Struktura bardzo ciężka do interpretacji

DRZEWA A SIECI NEURONOWE

- Drzewa decyzyjne:
 - Doskonałe do uwzględniania wiedzy eksperckiej...
 - ...Chyba, że wiedza ta wyrażana jest w postaci, np., równań różniczkowych
- Sieci neuronowe:
 - Nieprzystosowane do uwzględniania w naturalny sposób wiedzy eksperckiej...
 - ...Chyba, że przekłada się ona na wagi powiązań oraz funkcje aktywacji


ZDANIEM Marvinina Minsky'ego

- „ Some researchers hope that systems modeled on neural nets will quickly overtake more traditional systems based on symbol manipulation. Others believe that symbol manipulation remains the only viable approach. ”
- „ Artificial Intelligence must employ many approaches. The time has come to build systems out of diverse components, some connectionist and some symbolic, each with its own diverse justification. ”

PRZYKŁADOWE POLE DO POPISU

- Analiza dźwięku, obrazu, bądź danych multimedialnych, nie może opierać się ani wyłącznie na sieciach neuronowych, ani na, np., drzewach
- Konieczne jest połączenie metod numerycznych, naśladujących działanie ludzkich zmysłów, z metodami symbolicznymi, naśladującymi ludzkie rozumowanie

TRENING KLASYFIKATORA



UŻYCIE KLASYFIKATORA



> Classifier > Marks

UWAGA: TEN OBRAZ
NIE NALEŻY DO PRÓBK
TRENINGOWEJ!!!