

**Sieci neuronowe do przetwarzania informacji / Stanisław Osowski. –  
Wydanie IV, rozszerz. – Warszawa, 2020**

Spis treści

<b>Przedmowa</b>	<b>11</b>
<b>1. Wstęp</b>	<b>13</b>
1.1. Podstawy biologiczne działania neuronu	13
1.2. Pierwsze modele sieci neuronowej	16
1.3. Przegląd zastosowań sieci neuronowych	18
<b>2. Modele neuronów i metody ich uczenia</b>	<b>21</b>
2.1. Perceptron	22
2.2. Neuron sigmoidalny	23
2.3. Neuron radialny	28
2.4. Neuron typu adaline	29
2.5. Instar i outstar Grossberga	31
2.6. Neurony typu WTA	34
2.7. Model neuronu Hebba	38
2.8. Model stochastyczny neuronu	41
2.9. Zadania i problemy	43
<b>3. Sieci jednokierunkowe wielowarstwowe typu sigmoidalnego</b>	<b>44</b>
3.1. Sieć jednowarstwowa	45
3.2. Sieć wielowarstwowa perceptronowi	48
3.2.1. Struktura sieci perceptronowej	48
3.2.2. Algorytm propagacji wstecznej	49
3.3. Grafy przepływowe w zastosowaniu do generacji gradientu	53
3.4. Algorytmy gradientowe uczenia sieci	58
3.4.1. Zależności podstawowe	58
3.4.2. Algorytm największego spadku	60
3.4.3. Algorytm zmiennej metryki	61
3.4.4. Algorytm Levenberga-Marquardta	63
3.4.5. Algorytm gradientów sprzężonych	65
3.5. Dobór współczynnika uczenia	66
3.6. Metody heurystyczne uczenia sieci	69
3.6.1. Algorytm Quickprop	70
3.6.2. Algorytm RPROP	71
3.7. Program komputerowy MLP do uczenia sieci perceptronowej	72
3.8. Porównanie efektywności algorytmów uczących	73
3.9. Elementy optymalizacji globalnej	78
3.9.1. Algorytm symulowanego wyżarzania	81

3.9.2. Elementy algorytmów genetycznych	84
3.10. Metody inicjalizacji wag	89
3.11. Zadania i problemy	91
<b>4. Problemy praktycznego wykorzystania sieci neuronowych</b>	<b>93</b>
4.1. Zdolności generalizacyjne sieci neuronowych	93
4.1.1. Zależności podstawowe	93
4.1.2. Miara VCdim	94
4.1.3. Zależności między błędem generalizacji i miarą VCdim	95
4.1.4. Przegląd metod zwiększania zdolności generalizacyjnych sieci neuronowej	97
4.2. Wstępny dobór architektury sieci	102
4.3. Dobór optymalnej architektury sieci pod względem generalizacji	105
4.3.1. Metody wrażliwościowe redukcji sieci	106
4.3.2. Metody redukcji sieci z zastosowaniem funkcji kary	110
4.4. Wtrącanie szumu do próbek uczących	112
4.5. Zwiększanie zdolności generalizacyjnych przez użycie wielu sieci	115
4.6. Przykłady zastosowań sieci perceptronowej	117
4.6.1. Rozpoznawanie i klasyfikacja wzorców binarnych	117
4.6.2. Rozpoznawanie wzorców na podstawie obrysu zewnętrznego	126
4.6.3. Sieć neuronowa do kompresji danych	132
4.6.4. Identyfikacja obiektów dynamicznych	136
4.6.5. Predykcja obciążeń systemu elektroenergetycznego	139
4.7. Zadania i problemy	143
<b>5. Sieci neuronowe radialne</b>	<b>144</b>
5.1. Podstawy matematyczne	145
5.2. Sieć neuronowa radialna	147
5.3. Metody uczenia sieci neuronowych radialnych	153
5.3.1. Proces samoorganizacji w zastosowaniu do adaptacji parametrów funkcji radialnych	154
5.3.2. Algorytm probabilistyczny doboru parametrów funkcji radialnych	157
5.3.3. Algorytm hybrydowy uczenia sieci radialnych	159
5.3.4. Algorytmy uczące oparte na propagacji wstecznej	161
5.4. Metody doboru liczby funkcji bazowych	164
5.4.1. Metody heurystyczne	164
5.4.2. Metoda ortogonalizacji Grama-Schmidta	165
5.5. Program komputerowy uczenia sieci radialnych	170
5.6. Przykład zastosowania sieci radialnej w aproksymacji	172
5.7. Porównanie sieci radialnych z sieciami sigmoidalnymi	174
5.8. Zadania i problemy	176
<b>6. Sieci SVM</b>	<b>177</b>
6.1. Sieć liniowa SVM w zadaniu klasyfikacji	178
6.2. Sieć nieliniowa SVM w zadaniu klasyfikacji	184

6.3. Interpretacja mnożników Lagrange'a w rozwiązaniu sieci	192
6.4. Problem klasyfikacji przy wielu klasach	193
6.5. Sieci SVM do zadań regresji	194
6.6. Przegląd algorytmów rozwiązania zadania dualnego	197
6.7. Program komputerowy uczenia sieci SVM	201
6.8. Przykłady zastosowania sieci SVM	204
6.8. 1. Problem klasyfikacyjny dwu spiral	204
6.8.2. Rozpoznawanie tekstur	205
6.8.3. Wykrywanie uszkodzeń elementów w obwodzie filtru elektrycznego	207
6.9. Porównanie sieci SVM z innymi rozwiązaniami neuronowymi	209
6.10. Zadania i problemy	214
<b>7. Specjalizowane struktury sieci neuronowych</b>	<b>215</b>
7.1. Sieć kaskadowej korelacji Fahimana	215
7.2. Sieć Volterra	221
7.2.1. Struktura i zależności uczące sieci	222
7.2.2. Przykłady zastosowań sieci Volterra	225
7.3. Zadania i problemy	232
<b>8. Sieci rekurencyjne jako pamięci asocjacyjne</b>	<b>233</b>
8.1. Wprowadzenie	233
8.2. Sieć autoasocjacyjna Hopfielda	235
8.2.1. Zależności podstawowe	235
8.2.2. Tryb uczenia sieci Hopfielda	238
8.2.3. Tryb odtworzeniowy sieci Hopfielda	239
8.2.4. Program Hop win	240
8.3. Sieć Hamminga	243
8.3.1. Struktura sieci i algorytm doboru wag	243
8.3.2. Działanie sieci Hamminga	245
8.3.3. Program Shamming uczenia sieci	246
8.4. Sieć typu BAM	249
8.4.1. Opis działania sieci	249
8.4.2. Zmodyfikowany algorytm uczący sieci BAM	252
8.4.3. Zmodyfikowana struktura sieci BAM	253
8.5. Zadania i problemy	259
<b>9. Sieci rekurencyjne tworzone na bazie perceptronu</b>	<b>261</b>
9.1. Wprowadzenie	261
9.2. Sieć perceptronowa ze sprzężeniem zwrotnym	261
9.2.1. Struktura sieci RMLP	261
9.2.2. Algorytm uczenia sieci RMLP	263
9.2.3. Dobór współczynnika uczenia	265
9.2.4. Współczynnik wzmocnienia sygnału	266
9.2.5. Wyniki symulacji komputerowych	266

9.3. Sieć rekurencyjna Elmana	271
9.3.1. Struktura sieci	271
9.3.2. Algorytm uczenia sieci Elmana	273
9.3.3. Uczenie z wykorzystaniem momentu	275
9.3.4. Przykładowe wyniki symulacji komputerowych sieci Elmana	276
9.4. Sieć RTRN	280
9.4.1. Struktura sieci i algorytm uczący	280
9.4.2. Wyniki eksperymentów numerycznych	282
9.5. Zadania i problemy	286
<b>10. Sieci samoorganizujące się na zasadzie współzawodnictwa</b>	<b>287</b>
10.1. Zależności podstawowe sieci samoorganizujących się przez współzawodnictwo	287
10.1.1. Miary odległości między wektorami	289
10.1.2. Normalizacja wektorów	290
10.1.3. Problem neuronów martwych	291
10.2. Algorytmy uczące sieci samoorganizujących	292
10.2.1. Algorytm Kohonena	293
10.2.2. Algorytm gazu neuronowego	294
10.2.3. Program Kohon	296
10.2.4. Porównanie algorytmów samoorganizacji	298
10.3. Sieć odwzorowań jedno- i dwuwymiarowych	300
10.4. Odwzorowanie Sammona	303
10.5. Zastosowania sieci samoorganizujących	305
10.5.1. Kompresja danych	305
10.5.2. Wykrywanie uszkodzeń w urządzeniach	308
10.5.3. Krótkoterminowe prognozowanie obciążeń systemu elektroenergetycznego	311
10.6. Sieć hybrydowa	315
10.7. Zadania i problemy	319
<b>11. Sieci samoorganizujące typu korelacyjnego</b>	<b>321</b>
11.1. Funkcja energetyczna sieci korelacyjnych	321
11.2. Sieci neuronowe PCA	323
11.2.1. Wprowadzenie matematyczne	323
11.2.2. Relacja między przekształceniami PCA i SVD	326
11.2.3. Estymacja pierwszego składnika głównego	327
11.2.4. Algorytmy estymacji wielu składników głównych	328
11.3. Sieci neuronowe do ślepej separacji sygnałów	331
11.3.1. Zależności wstępne	331
11.3.2. Niezależność statystyczna sygnałów	332
11.3.3. Struktura rekurencyjna sieci separującej	333
11.3.4. Algorytm Heralta-Juttana dla sieci rekurencyjnej	335
11.3.5. Algorytm Cichockiego uczenia sieci rekurencyjnej	336
11.3.6. Program ślepej separacji BS	337

11.3.7. Sieć jednokierunkowa do separacji sygnałów	340
11.3.8. Toolbox ICALAB	346
11.4. Zadania i problemy	347
<b>12. Podstawy matematyczne systemów rozmytych</b>	<b>348</b>
12.1. Operacje na zbiorach rozmytych	350
12.2. Miary rozmytości zbiorów rozmytych	352
12.3. Rozmytość a prawdopodobieństwo	353
12.4. Reguły rozmyte wnioskowania	354
12.5. Systemy wnioskowania rozmytego Mamdaniego-Zadeha	356
12.5.1. Fuzyfikator	358
12.5.2. Defuzyfikator	362
12.5.3. Model Mamdaniego-Zadeha jako układ uniwersalnego aproksymatora	363
12.6. Model wnioskowania Takagi-Sugeno-Kanga	364
12.7. Zadania i problemy	367
<b>13. Sieci neuronowe rozmyte</b>	<b>369</b>
13.1. Struktura sieci rozmytej TSK	369
13.2. Struktura sieci Wanga-Mendela	373
13.3. Algorytmy samoorganizacji w zastosowaniu do uczenia sieci rozmytej	374
13.3.1. Algorytm grupowania górskiego	375
13.3.2. Algorytm C-means	378
13.3.3. Algorytm Gustafsona-Kessela samoorganizacji rozmytej	380
13.4. Generacja reguł wnioskowania sieci rozmytej	385
13.5. Algorytm hybrydowy uczenia sieci rozmytej TSK	388
13.6. Modyfikacje sieci TSK	392
13.6.1. Algorytm wyznaczania liczby reguł wnioskowania	393
13.6.2. Przykład numeryczny	395
13.6.3. Uproszczona sieć TSK	398
13.7. Sieć hybrydowa rozmyta	400
13.8. Przykłady zastosowań sieci rozmytych	402
13.8.1. Estymacja stężenia składników mieszaniny gazowej	403
13.8.2. Rozpoznawanie składników mieszanin gazowych	404
13.8.3. Rozpoznawanie gatunków piwa na podstawie zapachu	407
13.9. Adaptacyjny algorytm samoorganizacji dla sieci rozmytej	409
13.10. Zadania i problemy	412
<b>14. Głębokie sieci neuronowe</b>	<b>414</b>
14.1. Autoenkoder	415
14.2. Sieć o ekstremalnym uczeniu	424
14.3. Sieci konwolucyjne (CNN)	426
14.3.1. Opis struktury sieci CNN	427
14.3.2. Dobór struktury CNN	434

14.3.3. Uczenie sieci CNN	438
14.3.4. Przykłady zastosowania sieci CNN w Matlabie	442
14.4. Ograniczona maszyna Boltzmannna	451
14.4.1. Pojęcia wstępne	451
14.4.2. Algorytm uczenia sieci RBM	453
14.5. Sieć DBN	458
14.5.1. Struktura sieci DBN	458
14.5.2. Algorytm uczenia sieci DBN	459
14.6. Głębokie sieci rekurencyjne LSTM	459
14.6.1. Wprowadzenie	459
14.6.2. Zasada działania sieci LSTM	461
14.7. Przykłady praktycznych zastosowań sieci głębokich	465
14.8. Podsumowanie	473
<b>Bibliografia</b>	<b>475</b>
<b>Skorowidz</b>	<b>487</b>

oprac. BPK