

Krzysztof Ślot

Sztuczna inteligencja / Sztuczne sieci neuronowe

Zadanie nr ... – Studia podyplomowe „...”



KAPITAŁ LUDZKI
NARODOWA STRATEGIA SPÓJNOŚCI

UNIA EUROPEJSKA
EUROPEJSKI
FUNDUSZ SPOŁECZNY



Prezentacja multimedialna
współfinansowana przez Unię Europejską
w ramach Europejskiego Funduszu Społecznego
w projekcie

*„Innowacyjna dydaktyka bez ograniczeń
– zintegrowany rozwój Politechniki Łódzkiej –
zarządzanie Uczelnią,
nowoczesna oferta edukacyjna
i wzmacniania zdolności do zatrudniania
osób niepełnosprawnych”*



Politechnika Łódzka
Instytut Elektroniki

90-924 Łódź, ul. Żeromskiego 116,
tel. 042 631 28 83
www.kapitalludzki.p.lodz.pl



Wprowadzenie

- Skuteczność analizy informacji przez ludzki mózg jest niedościgniona (w wielu obszarach zagadnień)





Wprowadzenie

- Sztuczne sieci neuronowe – dziedzina AI inspirowana wiedzą o architekturze i sposobie funkcjonowania sieci neuronowych organizmów żywych
- Cel badań: uzyskać jakość przetwarzania osiąganą przez systemy nerwowe (w szczególności, przez ludzki mózg)
- Metodologia: szczegółowo poznać strukturę i sposób działania struktur nerwowych i wykorzystać tę wiedzę w formie algorytmów (i rozwiązań sprzętowych) przetwarzania informacji
- Podstawowe cechy struktur nerwowych wykorzystywane w badaniach:
 - prostota pojedynczego elementu sieci ('procesora')
 - równoległość przetwarzania
 - złożoność struktury
 - nabywanie wiedzy i umiejętności przez mechanizm uczenia (treningu)

Wprowadzenie

- Sieci neuronowe a klasyczna strategia przetwarzania danych (komputer)
- Architektura



Komputer: silne zróżnicowanie architektury elementów składowych: pamięć (prosta) procesor (złożony).

Sieć neuronowa: homogeniczność, równoległość, prostota procesora

- Sposób przetwarzania danych

Komputer: sekwencyjnie, bazuje na logice

Sieć neuronowa: równolegle, bazuje na prostych zasadach




Odniesienia biologiczne

- Architektura neuronu


Neuron: procesor o jednym wyjściu i wielu wejściach

Wejścia: synapsa-dendryt, wyjście: akson

Synapsy: pobudzające - hamujące




Działanie neuronu:



Częstotliwość impulsów generowanych przez neuron zależy od stopnia jego aktywacji – wypadkowego pobudzenia.


Obliczeniowe modele neuronu

- Model McCullocha-Pittsa: informacja zawarta w wartościach



Funkcje wyjściowe

Linowa



Tangens hiperboliczny

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


$$f(s) \in (-1 \dots 1)$$

Sigmoida


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

$$f(s) \in (0 \dots 1)$$

Nieliniowe, różniczkowalne



Nieliniowe, nieróżniczkowalne



Znak

$$f(s) = \text{sgn}(s)$$

$$f(s) \in (-1 \dots 1)$$


Skok

$$f(s) = 1(s)$$

$$f(s) \in (0 \dots 1)$$

Interpretacja funkcji neuronu

- Skokowa funkcja wyjścia:
 - przypisanie wektorowi wejściowemu binarnej wartości wyjściowej: klasyfikacja
- Interpretacja geometryczna




$$y = f(\mathbf{w}^T \mathbf{x}) = \begin{cases} \text{'aktywny'} \\ \text{'nieaktywny'} \end{cases}$$

Sygnalizacja położenia próbki względem hiperpłaszczyzny definiowanej przez współczynniki wagowe

Przestrzeń danych wejściowych (cech) jest dzielona na dwa obszary

Teoria sieci neuronowych

- Wynik klasyfikacji jest funkcją wektora wag
- Podstawowe zagadnienie teorii sieci neuronowych
 - dobór współczynników wagowych
- Metody doboru współczynników wagowych: przede wszystkim – uczenie



- Uczenie sieci: adaptacyjna korekta wartości współczynników wagowych
- Strategie rozwiązywania problemów:
 - Komputery: określ algorytm rozwiązania problemu
 - Sieci neuronowe: Określ sposób, w jaki sieć ma się uczyć rozwiązywać problem



Teoria sieci neuronowych

- **Uczenie nadzorowane sieci (supervised learning)**
 - istnieje możliwość określenia oczekiwanego wyniku przetwarzania danych przez wszystkie neurony i oceny poprawności działania tych neuronów (istnieje ‘nauczyciel’)
 - możliwe do wyznaczenia błędy stanowią podstawę do określania wymaganych korekt wartości jego wag
- **Uczenie nienadzorowane sieci (unsupervised learning)**
 - nie istnieje możliwość określenia oczekiwanego wyniku działania sieci (nie istnieje arbiter)
- **Uczenie ze wzmocnieniem (reinforcement learning)**
 - istnieje możliwość ogólnego określenia oczekiwanego wyniku działania sieci
 - ogólność oceny wyklucza możliwość ścisłego zdefiniowania błędów neuronów




Teoria sieci neuronowych

- Uczenie – proces wymagający dostarczenia przykładów
 - Uczenie nadzorowane: każdy przykład ma etykietę klasy
- Strategia uczenia:
 - Podział dostępnego zbioru przykładów na zbiory: treningowy i testowy
 - Przeprowadzenie wybranego algorytmu uczenia, korzystającego z przykładów zbioru treningowego i zmierzającego do ustalenie odpowiednich wartości współczynników wagowych
 - Sprawdzenie poprawności uczenia poprzez ocenę skuteczności działania sieci na elementach zbioru testowego
 - W razie niepowodzenia – powtórzenie poprzednich kroków z wykorzystaniem innych strategii szczegółowych


Teoria sieci neuronowych

- Liczność zbioru treningowego – funkcja liczby parametrów sieci




$$Ax^2 + Bx + Cxy + Dy + Ey^2 = 0$$


$$P = \{A, B, C, D, E\}$$



$$n \ll C$$



$$n \approx C$$




$$n \gg C$$

- Liczba przykładów musi zapewnić ilość informacji wystarczającą dla zbudowania poprawnego modelu zjawiska


Uczenie nadzorowane neuronu

- Uwarunkowania procesu

Zbiór treningowy : $\{x^i\}$
 Etykiety (oczekiwane odpowiedzi): $\{d^i\}$
 Rzeczywiste odpowiedzi: $\{y^i\}$



- Cel procesu
 - określić wartości współczynników wagowych, zapewniające zgodność oczekiwanych i rzeczywistych odpowiedzi neuronu.



Uczenie nadzorowane neuronu

- Kryterium doboru wag:
 - minimalizacja całkowitego błędu (różnic między oczekiwanymi a rzeczywistymi odpowiedziami neuronu)

Metodologia postępowania:
gradientowe metody optymalizacji

$$\Delta w_k = - \frac{\partial e_i}{\partial w_k}$$

- Podstawowa reguła korekty wag neuronu – reguła ‘delta


$$\Delta w_k = \eta \cdot (d^i - y^i) \cdot f'(s^i) \cdot x_k^i$$

- Szczegółowa postać reguły zależy od rodzaju funkcji aktywacji
 - skok jednostkowy:

$$\Delta w_k = \eta \cdot (d^i - y^i) \cdot x_k^i$$

Uczenie nadzorowane neuronu

- Interpretacja geometryczna uczenia neuronu





$$\Delta \mathbf{w} = \eta \cdot (d^i - y^i) \cdot \mathbf{x}^i$$

Kierunek: wektor $\mathbf{x}^i$ ($d^i - y^i$ jest ujemne)

Uczenie nadzorowane neuronu


- Funkcja neuronu: klasyfikacja liniowa (klasy w przestrzeni cech muszą być możliwe do rozdzielenia hiperpłaszczyzną)
- Dotkliwe ograniczenie – większość problemów rzeczywistych to problemy bardziej złożone



- Konstatacja ograniczeń (Minsky, Pappert, 1963) – regres w badaniach nad sztucznymi sieciami neuronowymi


Sieci neuronowe wielowarstwowe

- Dekompozycja złożonych problemów klasyfikacji



Sieci neuronowe wielowarstwowe


- Struktura dwuwarstwowa: binarne wejścia drugiej warstwy odpowiadają punktom półprzestrzeni
- Koniunkcja półprzestrzeni jest obszarem **wypukłym**
- Koniunkcja jest funkcją liniowo-separowalną



Sieci neuronowe dwuwarstwowe są w stanie przeprowadzić poprawną klasyfikację zbiorów nieseparowalnych liniowo









Sieci neuronowe wielowarstwowe

- Architektura:
 - sieci jednokierunkowe (informacja podąża w jednym kierunku)
- Warstwy ukryte:
 - Brak dostępu do sygnałów generowanych przez neurony
- Aplikacje struktury:
 - klasyfikacja danych



Sieci neuronowe wielowarstwowe

- Regiony decyzyjne dla sieci neuronowych jednokierunkowych

Structure	Types of decision regions	Exclusive-OR problem	Meshed regions	Most general region shapes
Template & 1-layer ANS 	Half plane bounded by hyperplane			
2-layer ANS 	Convex open or closed regions			
3-layer ANS 	Arbitrary (limited by number of nodes)			

Źródło: Lippman "Introduction to neural computing"

Sieci trójwarstwowe są w stanie zrealizować dowolne zadanie klasyfikacji



Klasyfikacja danych w sieciach neuronowych

- Podstawowa zaleta:
 - szybkość realizacji zadania (mnożenia, dodawania, podstawienia)
- Podstawowa wada:
 - trudność prawidłowego wyuczenia sieci

Metoda treningu: algorytm wstecznej propagacji błędu (BP) – uogólnienie reguły delta

 - trudność prawidłowego określenia optymalnej architektury sieci (liczby neuronów w poszczególnych warstwach)
- Pierwsza aplikacja:
 - automatyczny czytnik pisma (1987)