

Maciej Huk

Politechnika Wrocławska

WYBRANE WŁASNOŚCI SIECI NEURONOWEJ SIGMA-IF

I. Wstęp

Nasilająca się tendencja do gromadzenia coraz to większych zbiorów informacji oraz stałe zapotrzebowanie na skuteczne mechanizmy ich przetwarzania stwarzają konieczność równoczesnego poszukiwania coraz to bardziej wyrafinowanych metod analizy wielowymiarowych i heterogenicznych danych. Bardzo efektywną i skuteczną techniką w tej dziedzinie są sztuczne sieci neuronowe, które nie nakładają istotnych ograniczeń na heterogeniczność analizowanych informacji. Mimo to ich stosowanie w przypadku przetwarzania danych o bardzo dużej wymiarowości staje pod znakiem zapytania. Modele wykorzystywanych zwykle sieci neuronowych nie zapewniają bowiem wystarczających możliwości redukcji wymiarowości problemów rozwiązywanych przy ich pomocy.

W ramach badań zwrócono jednak uwagę na możliwość lokalnego rozszerzenia funkcji aktywacji klasycznego neuronu o dziedzinę czasu, istotnie wzbogacającego własności budowanych na tej podstawie sieci neuronowych [6; 7, s. 237-242]. Pojawiająca się w wyniku takiej modyfikacji zdolność do dynamicznego doboru wielkości rozważanej przestrzeni decyzyjnej jest związana z bieżącym dostosowywaniem architektury połączeń międzyneuronalnych do klasyfikowanych danych. Zmiany te pośrednio odzwierciedlają istotność poszczególnych atrybutów decyzyjnych dla klasyfikowanych wzorców, określoną w trakcie treningu proponowanej sieci Sigma-if. Wymienione cechy wskazują możliwość efektywnego funkcjonowania rozważanego automatu w rozwiązywaniu wielowymiarowych problemów klasyfikacji [8, s. 65-73].

Opisywane podejście jest również przykładem nowego, interesującego kierunku badań sieci neuronowych, stosujących technikę warunkowej akumulacji sygnałów wejściowych. Jak bowiem zostało to wykazane w dalszej części dokumentu

dla przypadku zadań klasyfikacji, wykorzystywanie podczas analizy danych ustalonego, pełnego wachlarza dostępnych informacji nie zawsze jest rozwiązaniem optymalnym.

Poświęcenie szczególnej uwagi jedynie wybranym własnościom proponowanego modelu jest podyktowane chęcią przedstawienia korzyści, jakie mogą płynąć z jego wykorzystywania, i zasygnalizowania jedynie związanych z tym nowych problemów, nie występujących w przypadku klasycznych sieci neuronowych. Bogatsze opracowania tej tematyki zainteresowany czytelnik może znaleźć w innych publikacjach autora.

2. Sieć neuronowa Sigma-if

Podstawowym składnikiem tradycyjnej sztucznej sieci neuronowej jest neuron, przetwarzający sygnały napływające poprzez jego wejścia za pomocą dwóch funkcji: funkcji aktywacji A i funkcji wyjściowej F (progującej). Pierwsza z nich określa poziom pobudzenia neuronu, druga zaś buduje jego odpowiedź, która przekazywana jest do innych obszarów sieci za pośrednictwem aksonu. Istotność funkcji wyjściowej, tak jak i wag przypisanych poszczególnym połączeniom międzyneuralnym, była szeroko analizowana w wielu publikacjach. Jednak prawie w każdym przypadku za funkcję aktywacji jest obierana liniowa kombinacja wartości wejściowych, co nie jest podyktowane ograniczeniami teoretycznymi. Analiza zachowań neuronów z odmiennymi funkcjami aktywacji może zaś prowadzić do poznania nowych typów struktur przetwarzających, posiadających ciekawe i użyteczne własności użytkowe [5, 11, s. 85-102; 13; 14].

Kierując się powyższymi wskazówkami, na bazie klasycznego neuronu został skonstruowany jego odpowiednik, którego funkcja aktywacji wykracza poza schemat liniowej kombinacji sygnałów wejściowych. Dendryty neuronu Sigma-if w liczbie M są dzielone na K rozłącznych grup poprzez przypisanie każdemu i -temu wejściu dodatkowego parametru θ_i , którego wartość oznacza przynależność do jednej z grup. Podział wejść pozwala z kolei rozbić proces akumulacji sygnałów wejściowych na K kroków, a w proponowanym rozwiązaniu odbywa się według następującego schematu. W każdym kroku k akumulowane są pobudzenia z wejść należących do jednej z grup – czyli dla których:

$$\theta_i = k, \quad (1)$$

przy czym w ramach danej grupy pobudzenie Δg wyliczane jest jako ważona suma sygnałów wejściowych:

$$\Delta g = \sum_{i=1}^M w_i x_i \delta(k, \theta_i). \quad (2)$$

Proces ten prowadzony jest do momentu, gdy suma pobudzeń pochodzących od przeanalizowanych grup przekroczy ustaloną z góry, progową wartość aktywacji neuronu net^* :

$$net(k) = \begin{cases} \Delta g \cdot H(net^* - net(k-1)) + net(k-1) & : k \geq 0 \\ 0 & : k < 0 \end{cases} \quad (3)$$

gdzie H to funkcja Heaviside'a. Suma ta zostaje wówczas uznana za pobudzenie neuronu i stanowi parametr wejściowy dla funkcji progującej. Sygnały z wejść należących do pozostałych nieprzeanalizowanych grup są zaniechane. W przypadku gdy suma pobudzeń od wszystkich grup nie przekroczy wartości granicznej net^* , uznaje się, iż neuron nie otrzymał informacji wystarczających do podjęcia decyzji, funkcja pobudzenia zaś przyjmuje wartość zerową. Ostatecznie przyjmuje więc ona postać:

$$A = \begin{cases} net(K) & : net(K) \geq net^* \\ 0 & : net(K) < net^* \end{cases} \quad (4)$$

Funkcja ta wyróżnia pierwotną postać neuronu Sigma-if i została podana dla zachowania zgodności z wcześniejszymi publikacjami na ten temat. Badania pokazały jednak, iż sztuczne założenie o jej zerowaniu się, w przypadku nieprzekroczenia przez pełną sumę pobudzeń wartości progowej net^* , może zostać pominięte, a funkcja aktywacji określona jako:

$$A = net(K). \quad (5)$$

Podejście takie zachowuje wszystkie istotne własności ujęcia przedstawionego wcześniej i, obok bardziej zwartej zapisu, upraszcza i ułatwia proces treningu budowanych na ich podstawie sieci neuronowych. W dalszej części artykułu odwoływać się więc będziemy do neuronu Sigma-if z funkcją aktywacji postaci (5).

Konstrukcja taka posiada czytelną biologiczną interpretację. W przypadku bowiem neuronów rzeczywistych, poszczególne dendryty cechują się różnymi, niezerowymi długościami, przez co transport informacji odbywający się dzięki nim nie jest ani natychmiastowy, ani skorelowany w ramach różnych połączeń. Zjawisko to jest jednym z elementów pozwalających rzeczywistej sieci neuronowej identyfikować napływające sygnały z określonymi wejściami czy obszarami przetwarzającymi. W świetle tego, numery grup połączeń wejściowych sztucznego neuronu zyskują interpretację długości lub, co bardziej intuicyjne, czasów przepływu sygnałów przez połączenia międzyneuralne [1; 3]. Przedstawiona modyfikacja klasycznego neuronu zakłada więc zmianę charakteru sposobu wyliczania pobu-

dzenia neuronu – z natychmiastowego na proces lokalnie rozciągliwy w czasie. Wspomnianych tu opóźnień nie należy jednak mylić z opóźnieniami w sieciach wykorzystujących wejściowe linie opóźniające lub filtry FIR. Z tego względu, dla uniknięcia nieporozumień, pozostaniemy przy określeniu dodatkowych parametrów θ ; mianem składowych wektora grupującego Θ .

Zbudowana na podstawie przedstawionego modelu neuronu sieć Sigma-if funkcjonuje analogicznie do jednokierunkowej sieci neuronowej – przepływ sygnałów poprzez pełną sieć połączeń jest synchronizowany w kolejnych warstwach neuronów ukrytych. Bez zmian pozostają także metody kodowania informacji prezentowanych automatowi i dekodowania jego wyjść. Odmienna natomiast jest metoda jego uczenia, polegająca w tym przypadku na doborze wektora wag oraz grupującego. O ile jednak w przypadku doboru wag można bez znaczących zmian zastosować powszechnie znany algorytm wstecznej propagacji błędów, o tyle problem wyboru składowych wektora grupującego jest zagadnieniem tak szerokim, iż wymaga odrębnego opracowania. W tym miejscu warto jednak wspomnieć, że w ramach dotychczasowych badań były stosowane w tej kwestii niezależnie dwa podejścia: symulowane wyżarzanie oraz wybór losowy [6; 8, s. 65-73].


3. Własności sieci Sigma-if

Przedstawiony wyżej model neuronu realizującego technikę warunkowej akumulacji sygnałów wejściowych ma wiele cech odróżniających go od dotychczas rozważanych jednokierunkowych sieci neuronowych. W ramach tego artykułu skupimy się jednak wyłącznie na trzech najistotniejszych aspektach jego funkcjonowania. Podyktowane jest to zarówno ograniczoną objętością referatu, jak i potrzebą dalszych badań wynikającą z ciągle niepełnego poznania przedmiotu rozważań.

3.1 Rozszerzenie zdolności klasyfikacyjnych

Pierwsza z cech może być odczytana bezpośrednio z formuł opisujących jego zachowanie neuronu – każdy neuron Sigma-if, zanim podejmie decyzję o podaniu na wyjście określonej wartości, może wielokrotnie badać różne hipotezy dotyczące podanych na jego wejście sygnałów. Dokładnie rzecz ujmując, wytrenowany neuron tego typu może próbować partycjonować przestrzeń danych hiperpłaszczyznami o coraz to większej liczbie wymiarów. Maksymalna liczba prób w trakcie wyznaczania pobudzenia neuronu jest determinowana tu przez liczbę grup K , na które podzielone są jego wejścia. Własność ta istotnie rozszerza zdolności klasyfikacyjne neuronowych jednostek przetwarzających. Jak pokazuje doświadczenie, dzięki niej pojedynczy neuron Sigma-if, mimo wykorzystywania w jego ciele liniowej bądź sigmoidalnej funkcji progującej, w odróżnieniu od klasycznego neuronu jest w stanie rozwiązywać zadania z klasy problemów liniowo nieseparowalnych. Najprostszy tego przykładem jest neuron dwuwejściowy, który w przypadku gdy oba

jego dendryty przynależą do różnych grup połączeń, może realizować funkcje zbliżone do funkcji XOR (rys. 1).



Rys 1. Schemat neuronu Sigma-if rozwiązującego problem liniowo nieseparowalny (zmodyfikowaną funkcję XOR) oraz fragment jego przestrzeni decyzyjnej

Jeśli w neuronie podanym na powyższym schemacie za funkcję progującą F przyjmiemy sigmoidę bipolarną, a jego wartości wyjściowe Y mniejsze lub równe i większe niż 0,5 będziemy postrzegali odpowiednio jako klasy 0 i 1, model ten będzie poprawnie rozwiązywał problem liniowo nieseparowalny, zdefiniowany przez poniższą funkcję:

$$D(x_1, x_2) = \begin{cases} 0 : (x_1, x_2) \in \{(0,0), (0.8,0.8)\} \\ 1 : (x_1, x_2) \in \{(0,1), (1,0)\} \end{cases} \quad (6)$$

Podejście to jednak zawodzi w przypadku oryginalnej funkcji XOR. Wynika to zarówno z charakteru metody jak i ze specyfiki samego problemu – w tym przypadku na każdej prostej, prostopadłej do jednego z wymiarów przestrzeni danych, przechodzącej przez wybrany punkt danych uczących z klasy C, leży punkt z klasy różnej od C. Uniemożliwia to separację tych punktów poprzez proste prostopadłe do wybranych wektorów przestrzeni. W podobnych przypadkach można jednak rozważyć rozwiązanie polegające na obrocie układu współrzędnych o wybrany kąt ostry. Po takim przekształceniu pojedynczy neuron Sigma-if jest w stanie poprawnie klasyfikować punkty definiujące funkcję XOR.

3.2. Niedestryktywna eliminacja połączeń

Dostrzeżenie kolejnej interesującej własności proponowanego rozwiązania, choć ma ona rodowód identyczny jak ta rozważana poprzednio, wymaga zwrócenia uwagi na możliwości pomijania części grup połączeń podczas pracy neuronu Sigma-if. W związku z tym można wyodrębnić pojęcie aktywności połączenia międzyneuronalnego, określające przynależność danego połączenia do jednej z grup wejść wybranego neuronu, które podczas określania jego wartości wyjściowej wniosły wkład do wartości jego pobudzenia. Pojęcie to było zbędne w przypadku

zwykłych jednokierunkowych sieci neuronowych, w których wszystkie wejścia są zawsze aktywne [5; 12]. Jednak w odniesieniu do rozważanego modelu pozwala ono nam stwierdzić, iż sieć Sigma-if realizuje ideę niedestruktywnej eliminacji połączeń międzyneuronalnych. W trakcie zarówno działania, jak i uczenia wyłącza ona z obliczeń (deaktywuje) połączenia w danej chwili niepotrzebne, nie eliminując jednak możliwości ich użycia (aktywacji) w innych przypadkach. W praktyce przekłada się to zwykle na zauważalne przyspieszenie funkcjonowania wytrenowanej sieci.

Idąc dalej tym tropem, łatwo zauważyć, że dla poprawnie wytrenowanej sieci Sigma-if analiza aktywności jej wejść wskazuje bezpośrednio przesłanki, na podstawie których sieć buduje swoje odpowiedzi. Dzięki temu może ona znaleźć zastosowanie tam, gdzie niedopuszczalne jest wykorzystywanie automatów typu „czarna skrzynka” [2; 9; 10]. Doświadczenia pokazują, że budowa listy aktywności wejść sieci może być także jednym z elementów analizy w procesie pozyskiwania wiedzy z danych.

3.3. Organizacja pamięci

Ostatnia z omawianych tu cech proponowanego rozwiązania związana jest ze sposobem przechowywania informacji przez sieć Sigma-if. O ile w przypadku klasycznych sieci neuronowych mieliśmy do czynienia jedynie z enigmatycznym, rozproszonym zapisem wiedzy, o tyle ich rozszerzenie przedstawione wyżej nakłada na ten zapis ograniczenia o określonej strukturze i semantyce. Można powiedzieć, iż w efekcie reprezentacja wiedzy w sieci Sigma-if ma charakter rozproszonej lokalnie i ustrukturalizowanej globalnie.

Potwierdzeniem tego, obok przesłanek teoretycznych, wydają się być rezultaty porównania efektów ekstrakcji wiedzy z sieci neuronowych typu Sigma-if i ich klasycznych odpowiedników. Zaznaczyć należy, iż pozyskiwanie wiedzy z sieci było wykonywane za pomocą algorytmu Trepan, uznawanego w literaturze za jeden z najlepszych w tej dziedzinie, docelową zaś jej postacią były drzewa decyzyjne [2; 4].

Tabela 1. Procentowe zmiany wielkości określających rozmiary drzew decyzyjnych pozyskanych z sieci Sigma-if w stosunku do ich odpowiedników dla klasycznych jednokierunkowych sieci neuronowych oraz porównanie poprawności ich klasyfikacji dla zbiorów testowych wybranych problemów

Nazwa problemu	Zmiana rozmiaru drzewa [%]		Poprawność klasyfikacji [%]	
	liczba węzłów	liczba liści	sieć klasyczna	sieć Sigma-if
Iris	50	40	94	94
Sonar	3.8	2.4	87.2	90.4
Heart	11.1	9.1	83.5	83.9
Vote	28.5	26.6	94.1	98.5

Źródło: opracowanie własne.

Jak pokazuje tab. 1., niezależnie od rozwiązywanych przez sieci problemów, opisujące je drzewa decyzyjne cechowały się lepszymi własnościami, jeśli poz-

skane były z sieci Sigma-if. Przy zachowaniu bowiem podobnej dokładności klasyfikacji składały się one z mniejszej liczby węzłów oraz liści. Z kolei charakterystyczną cechą algorytmu Trepan jest to, iż rozmiary i poprawność klasyfikacji budowanych przez niego drzew decyzyjnych są ściśle skorelowane ze stopniem organizacji przestrzeni decyzyjnej badanych klasyfikatorów.

Kwestia organizacji pamięci w sieci Sigma-if ma jednak jeszcze jedno, bardzo interesujące oblicze. Wektor wag, podobnie jak w typowej sieci neuronowej, odpowiada za przechowywanie wiedzy deklaratywnej. Wektor grupujący odpowiada zaś za zapis wiedzy w postaci proceduralnej. Przy tak istotnym rozszerzeniu nie powinno dziwić pojawianie się w przypadku proponowanego modelu, niekiedy nawet zaskakujących własności.

4. Podsumowanie

Kończąc prezentację modelu sieci Sigma-if, warto jeszcze raz przywołać najistotniejsze jej własności. Należą do nich zdolność do niedestruktywnej eliminacji połączeń międzyneuralnych oraz rozszerzone możliwości klasyfikacyjne. Ich pośrednią konsekwencją są możliwości wykorzystania proponowanego modelu sieci w zadaniach wymagających objaśniania sposobu wnioskowania automatów oraz w procesie pozyskiwania wiedzy z danych. Ta ostatnia zaś pojawia się nie tylko ze względu na możliwość analizy aktywności wejść poszczególnych neuronów w procesie wyznaczania ich pobudzeń, ale z powodu organizowania i rozszerzenia jej struktur pamięci o możliwość przechowywania wiedzy proceduralnej.

Podkreślić jednak należy, iż pełne wykorzystanie możliwości przedstawionego modelu jest możliwe wyłącznie w przypadku stosowania skutecznej metody wyboru składowych wektora grupującego. Zastosowanie do tego celu wspomnianych w tekście prostych heurystyk pozwoliło uzyskać bardzo interesujące rezultaty. Ostateczne rozwiązanie tego zagadnienia nie zostało jednak jeszcze znalezione, co wyznacza kierunki dalszych prac nad sieciami typu Sigma-if.

Podziękowanie

Powyższe badania z zakresu inteligentnych systemów informacyjnych i uczenia maszynowego, finansowane są przez Polskie Ministerstwo Nauki i Informatyzacji w ramach grantu badawczego 4 T11C 02425.

Literatura

- [1] Abeles M., *Role of the Cortical Neuron: Integrator or Coincidence Detector?*, Israel J. Med. Sci., 18:83-92, 1982.
- [2] Andrews R., Diederich J., Tickle A.B., *Survey and Critique of Techniques for Extracting Rules from Trained Artificial Neural Networks*, Queensland University of Technology, 1995.

- [3] Cohen S., Intrator N., *A Hybrid Projection Based and Radial Basis Function Architecture*, Initial values and global optimization, Lecture Notes in Computer Science, 2001.
- [4] Craven M., Shalvik J.: *Using Neural Networks for Data Mining*, Carnegie Mellon University, 1997.
- [5] Duch W., Jankowski N., *Transfer Functions: Hidden Possibilities for Better Neural Networks*, Nicholas Copernicus University, 2001.
- [6] Huk M., *Określanie istotności atrybutów w zadaniach klasyfikacyjnych przez niedestruktywną eliminację połączeń w sieci neuronowej*, Pozyskiwanie Wiedzy z Baz Danych, AE, Wrocław 2003.
- [7] Huk M., *Modelowanie sieci neuronowej Sigma-if, Metody i Systemy Komputerowe w Nauce i Technice*, Kraków, 2003.
- [8] Huk M., *The Sigma-if Neural Network as a Method of Dynamic Selection of Decision Subspaces for Medical Reasoning Systems*, „Journal of Medical Informatics & Technologies” 2004 vol. 7.
- [9] Kaski S., *Data Exploration Using Self-Organizing Maps*, Helsinki University of Technology, 1997.
- [10] Kavzoglu T., Mather P.M., *The Use of Feature Selection Techniques in the Context of Artificial Neural Networks*, University of Nottingham 2000.
- [11] Luo Z.A., Tseng P., *Analysis of an Approximate Gradient Projection Method with Application to the Backpropagation Algorithm*, „Optimization Methods and Software”, 1994 vol. 4, no 2.
- [12] Prechelt L., *Connection Pruning with Static and Adaptive Schedules*, Neurocomputing, 1997.
- [13] Pui-Fai Sum J., *Extended Kalman Filter Based Pruning Algorithms and Several Aspects of Neural Network Learning*, The Chinese, University of Hong Hong 1998.
- [14] Setino R., Loew W.K., *FERNN: An Algorithm for Fast Extraction of Rules from Neural Networks*, „Applied Intelligence” 2000 vol. 12.

CHOSEN PROPERTIES OF THE SIGMA-IF NEURAL NETWORK

Summary

This article presents the results of research on the Sigma-if neural network model. In spite of its simple structure and the use of standard, synchronous working and learning methods, it possesses important properties that are unattainable for classic perceptron networks. Due to expanding the domain of neuronal activation functions to include the time dimension and by extending the interneuronal connection attribute set, this structure realises the idea of nondestructive interneuronal connection elimination. It is capable - when working as well as when training - of excluding interneuronal connections which are irrelevant at a given moment, without completely eliminating the possibility of using them in other cases.

Special attention is devoted to the possibility of correct solving the linearly inseparable problems by single Sigma-if neuron, even though it uses simple sigmoidal threshold function (as in case of classical perceptron, which hasn't such properties) Analysis of this fact is supplemented by its biological interpretation. Results of experiments are presented along with graphical illustrations of decision spaces of example functioning models.

The presentation mentioned above provides the necessary background for a discussion on the networks' mathematical functional model and properties. The author derives functions, which describe the dynamics of each individual Sigma-if neuron and the automaton as a whole. The theoretical description is supplemented by a number of application examples, which show the legitimacy and promise of the Sigma-if model. The article is augmented by descriptions of key experiments, along with analyses of their results.