

Jan CHOJCAN
Katarzyna MOŚCIŃSKA
Jerzy RUTKOWSKI
Grzegorz TYMA

Instytut Elektroniki
Politechniki Śląskiej

SIECI NEURONOWE - UOGÓLNIENIE ALGORYTMU UCZENIA SIECI BACK-PROPAGATION, ZASTOSOWANIE DO ROZPOZNAWANIA LINII PAPILARNYCH, CYFR I LOKALIZACJI USZKODZEŃ W NIELINIOWYCH OBWODACH DC

Streszczenie. Ostatnie lata przyniosły duże zainteresowanie sieciami neuronowymi. Spowodowane jest ono możliwością zastosowania sieci neuronowych w zadaniach, dla których nie istnieją inne rozwiązania lub są to rozwiązania niezadawalające. Zaproponowano wiele struktur sieci neuronowych i różne sposoby ich uczenia. Artykuł ten prezentuje wyniki prac prowadzonych przez autorów w ciągu ostatnich trzech lat.

NEURAL NETWORKS - GENERALIZATION OF ERROR BACK-PROPAGATION LEARNING ALGORITHM, APPLICATIONS TO FINGERPRINT CLASSIFICATION, DIGIT RECOGNITION AND FAULT DIAGNOSIS IN NONLINEAR DC CIRCUITS

Summary. Over the past decade the artificial neural networks have received a great deal of interest. Much of the excitement of studying neural networks lies in their potential in applications especially in the field of signal processing and pattern recognition, for which solutions have not been found through conventional computing. A lot of different neural network models have been proposed for various problems, different learning algorithms have been invented. This paper presents our domains of interest in neural networks. We demonstrate our results which have been achieved in the last few years.

STRUCTURES NEUROLOGIQUES - GENERALISATION DE L'ALGORITHME D'APPRENTISSAGE DE RESEAU BACK-PROPAGATION, APPLICATION A L'IDENTIFICATION DES EMPREINTES DIGITALES ET DES CHIFFRES, AINSI QU'A LA LOCALISATION D'UN DERANGEMENT DANS LES CIRCUITS NON-LINEAIRES DC

Resumé. Depuis la dernière décennie, la structure artificielle neurologique est devenue un grand centre d'intérêt. La plupart de l'engouement à étudier les structures neurologiques découle de leur potentiel dans des applications où les solutions ne peuvent être trouvées par un calcul conventionnel. Beaucoup de différents modèles de structures neurologiques ont été proposés diverses, différents algorithmes d'apprentissage ont été inventés. Ce papier présente le domaine de la structure neurologique qui nous intéresse. Nous démontrons les résultats que nous avons obtenus les deux dernières années.

1. Uogólnienie algorytmu uczenia sieci back-propagation z wykorzystaniem twierdzenia Tellegena [1]

Algorytm uczenia zaproponowany w 1985 roku przez D.Rumelharta, G.Hintona i R.Williamsa [2], noszący nazwę algorytmu wstecznej propagacji błędu, znalazł liczne praktyczne zastosowania. Pozwala on na obliczenie pochodnych zdefiniowanej funkcji błędu względem wag połączeń sieci. Wyliczone wartości używane są następnie przez jedną z metod minimalizujących funkcję błędu poprzez zmiany wag. Zaproponowano wiele różnych algorytmów modyfikacji wag i współczynnika uczenia, ale żaden z nich nie zapewnia znalezienia globalnego minimum. Zbieżność zależy od kształtu funkcji błędu, punktu startowego, współczynnika uczenia, uporządkowania zbioru uczącego. Algorytm wstecznej propagacji błędu zaproponowano dla sieci bez sprzężeń zwrotnych, z sigmoidalną funkcją aktywacji węzłów sieci. Autorzy uogólnili ten algorytm, korzystając z twierdzenia Tellegena, na sieci ze sprzężeniami zwrotnymi i dowolnymi różniczkowalnymi funkcjami aktywacji.


Opis metody

Modyfikując metodę opisaną przez A.Fettweisa [3], opartą na twierdzeniu Tellegena dla grafów, autorzy stworzyli nowy algorytm uczenia sieci neuronowych.


Zdefiniujemy funkcję błędu w postaci: $E = \sum_p E_p = 0.5 \sum_p (out_p - t_p)^2$,

gdzie: E_p - błąd dla pary uczącej p , out_p - aktualny sygnał na wyjściu sieci dla pary uczącej p , t_p - żądany sygnał na wyjściu sieci.

W celu minimalizacji funkcji błędu obliczane są pochodne funkcji błędu E podług wag w_{ij} . Wartości te są następnie wykorzystywane przez metodę minimalizacyjną.



Rys. 1. Przykład sieci neuronowej
Fig. 1. Example of neural network




Rys. 2. Graf dla sieci z rys. 1
Fig. 2. Graph for network from fig. 1

Zaproponowany algorytm uczenia składa się z następujących etapów:

- sieć neuronowa opisywana jest przy użyciu grafu (graf podstawowy) (wagi połączeń i funkcje aktywacji reprezentowane są przez gałęzie grafu, natomiast w węzłach grafu obliczana jest suma dochodzących sygnałów) - rys. 1, rys. 2,
- dla grafu podstawowego obliczany jest punkt pracy (x_i oznacza stan i -tego węzła w grafie podstawowym),
- dla grafu dołączonego obliczany jest punkt pracy (graf dołączony tworzony jest przez linearyzację grafu podstawowego w punkcie pracy i inwersję, na wejście grafu dołączonego podawana jest wartość pochodnej funkcji błędu podług aktualnej wartości sygnału wyjściowego w grafie podstawowym, x'_j oznacza stan j -tego węzła w grafie dołączonym) - rys. 3.

Poszukiwana wartość pochodnej wyliczana jest jako iloczyn odpowiednich stanów węzłów w grafie podstawowym i dołączonym:

$$\frac{\partial E}{\partial w_{ij}} = x_j \cdot x'_i$$



Rys. 3. Graf dołączony do grafu z rys. 2
Fig. 3. Adjoint graph for graph from Fig. 2

Obliczone wartości wykorzystywane są następnie w dowolnej metodzie minimalizacyjnej, pierwszego rzędu.

Zaproponowany algorytm pozwala na obliczanie żądanych pochodnych dla dowolnych sieci neuronowych bez sprzężeń zwrotnych i stabilnych sieci ze sprzężeniami zwrotnymi z różniczkowalnymi funkcjami aktywacji.

2. Klasyfikacja śladów linii papilarnych z wykorzystaniem sieci neuronowych [4]

Ślady linii papilarnych są dziś powszechnie wykorzystywane w nowoczesnej kryminalistyce, a także w innych dziedzinach wymagających bezbłędnej i szybkiej identyfikacji tożsamości, takich jak ochrona depozytów bankowych, ważnych obiektów technologicznych. Podstawowymi cechami decydującymi o przydatności śladów linii papilarnych są ich **jednoznaczność** oraz **niezmiennność w czasie**.

Warunkiem wykorzystania śladów linii papilarnych jest odpowiednie ich zakodowanie, tak by porównanie testowego śladu z próbkami zgromadzonymi w bazie danych odbywało się w dostatecznie krótkim (zależnym od aplikacji) czasie. Wskazane jest także, by identyfikacja była realizowana w oparciu o **pojedynczy** ślad linii papilarnych, nie zaś o tzw. dziesięciopalcową formułę daktyloskopijną, co po dziś dzień ma miejsce w polskiej kryminalistyce [5].

Podstawowym celem naszej pracy było stworzenie systemu służącego do opisu i klasyfikacji pojedynczych śladów linii papilarnych. Szczególny nacisk położono na wstępną fazę klasyfikacji, prowadzącą do wyznaczenia podstawowej kategorii śladu. Dalsza klasyfikacja (w ramach wyznaczonej kategorii) jest realizowana w oparciu o

szczegółową analizę poszczególnych linii papilarnych i może być zautomatyzowana jedynie częściowo - wysoką wiarygodność klasyfikacji uzyskuje się wyłącznie przy analizie ręcznej bądź interakcyjnej.

Ślady linii papilarnych

Pojedynczy rysunek linii papilarnych składa się z dziesiątków linii kreślących różnorodne wzory, takich jak pętlice, łuki i spirale. W ramach rysunku można wyróżnić pewne charakterystyczne struktury, wśród których najważniejsze to:


- delta - punkt, w którym rozdzielają się dwa biegnące równolegle grzbieity (dwie linie papilarne);
- punkt centralny - w przybliżeniu środek wzoru spiralnego, zlokalizowany na najbliższym środku grzbiecie spirali.

Analiza przebiegu poszczególnych grzbieców pozwala na rozróżnienie jednej z podstawowych kategorii śladów linii papilarnych, które definiowane są różnie w poszczególnych systemach kryminalistycznych. W pracy przyjęliśmy następujące kategorie: łuk zwykły, łuk namiotowy, pętlica, wzór spiralny [5].

Dalsza analiza śladu odbywa się w oparciu o tzw. minucje, czyli początki, zakończenia, rozwidlenia, mostki itp. poszczególnych grzbieców. Druga faza klasyfikacji nie była przedmiotem niniejszej pracy [4][6].

Przetwarzanie śladów linii papilarnych


Przetwarzanie śladów linii papilarnych wymaga ich akwizycji oraz wstępnej obróbki, w celu zarówno odszumienia, jak i zredukowania informacji będącej podstawą klasyfikacji. Rys. 4. przedstawia schemat blokowy procesu przetwarzania śladów linii papilarnych.



Rys. 4. Proces przetwarzania śladów linii papilarnych
Fig. 4. Fingerprint evaluation



Rys. 5. Ślad linii papilarnych
Fig. 5. Example of a fingerprint




Rys. 6. Odcisk po progowaniu
Fig. 6. Two-level fingerprint

Ślady uzyskane z kart daktyloskopijnych zastały odczytane skanerem z rozdzielczością 300 dpi jako obrazy o 256 poziomach szarości i rozmiarze 256x256 pikseli. Przykładowy ślad linii papilarnych pokazano na rys. 5. Przetwarzanie zarejestrowanych śladów odbywało się za pomocą własnoręcznie stworzonego oprogramowania i obejmowało wstępną obróbkę zarejestrowanych śladów oraz właściwą klasyfikację. Celem pierwszego etapu przetwarzania było maksymalne uwypuklenie konturów linii papilarnych poprzez wielokrotną filtrację obrazu za pomocą operatorów lokalnych, spośród których najlepsze rezultaty dało zastosowanie operatora Laplace'a oraz filtru dolnoprzepustowego [7]. Kolejny etap przetwarzania obejmował różnorodne algorytmy progowania w celu uzyskania obrazu binarnego (rys. 6), a następnie szkieletowanie według algorytmów jedno- oraz wieloprzebiegowych [7,8] (rys. 7). Uzyskany obraz szkieletowy został podzielony na 64 kwadraty o rozmiarze 32x32 piksele. W każdym z kwadratów wyznaczono dominujący kierunek linii papilarnych (rys. 8), będący podstawą dalszej klasyfikacji.



Rys. 7. Szkielet odcisku
Fig. 7. Skeleton of the fingerprint



Rys. 8. Kody kierunkowe
Fig. 8. Directional codes

Klasyfikacja śladów linii papilarnych

W celu klasyfikacji przetworzonych śladów linii papilarnych zastosowano samoorganizującą sieć Kohonena [9]. Liczba węzłów sieci była zmieniana w trakcie eksperymentów; prawidłowa klasyfikacja ma miejsce, gdy liczba ta jest kilkakrotnie większa od liczby wykrywanych struktur, tzn. każdy klaster jest reprezentowany przez kilka słów kodowych. Sygnałami wejściowymi były 9-elementowe wektory, utworzone z losowo wybieranych kwadratów o rozmiarach 3x3.


Po zakończeniu nienadzorowanego procesu samoorganizacji zrealizowano testowanie sieci wektorami wejściowymi odpowiadającymi tym fragmentom śladu papilarnego, które zawierają wzory deltowe, punkt centralny itp. w celu ustalenia tych węzłów sieci, które odpowiadają na pobudzenie danym wzorcem. Wykrycie rodzaju i liczby struktur podstawowych umożliwia klasyfikację na omówione wcześniej podstawowe kategorie. Następnie przetestowano sieć podając wektory wejściowe nie prezentowane w trakcie uczenia. Uzyskano następujące rezultaty: poprawnie zaklasyfikowano 95% śladów, z których pobierano wektory uczące i 80% śladów nie wchodzących w skład zbioru uczącego. Uzyskanie lepszego odsetka poprawnych wskazań wymaga zastosowania większej rozdzielczości obrazu binarnego, co jednak prowadzi do zwiększenia nakładu obliczeń.

3. Rozpoznawanie cyfr z wykorzystaniem sieci neuronowych [10]

Początki automatycznego rozpoznawania znaków datują się na lata trzydzieste naszego stulecia. W ciągu ostatnich lat zaproponowano wiele metod i systemów mających wykonywać to zadanie. Każdy proces rozpoznawania można podzielić na następujące etapy: akwizycję obrazu, przetwarzanie wstępne, ekstrakcję cech i klasyfikację. W ostatnim okresie podejmowanych jest wiele prób wykorzystania sieci neuronowych do zadań rozpoznawania różnych obiektów (sygnałów biomedycznych, obrazów, głosu) [11]. Jedna z grup zastosowań wykorzystuje klasyczne metody ekstrakcji cech, a sieci neuronowe działają tylko jako klasyfikatory. Druga grupa stara się wykorzystać sieci także do ekstrakcji cech.

Opis systemu do rozpoznawania cyfr

System do rozpoznawania cyfr składa się z następujących elementów: sprzętu do akwizycji danych, bloku przetwarzania wstępnego, sieci neuronowej trzeciego rzędu (ekstraktor cech) i sieci LVQ (Learning Vector Quantization) [12]



Rys. 9. System rozpoznający cyfry
Fig. 9. Recognition system

(lub sieci back-propagation) (klasyfikatora) (rys. 9). Wzorce cyfr wprowadzane są za pomocą digitizera lub myszki przy użyciu odpowiedniego oprogramowania. Znaki reprezentowane są przez mapę pikseli s_i , $i=1\dots N$ (w naszym przypadku $N=16\times 16$).

Dla każdego znaku wyliczany jest, z użyciem sieci neuronowej trzeciego rzędu, wektor cech. Cechy określają liczbę trójkątów podobnych rozpiętych na konturze znaku, podzielonych na grupy według miary kątów wewnętrznych. Obliczony wektor cech podawany jest na wejście klasyfikatora. Książka kodowa klasyfikatora LVQ zawiera 40

wektorów 32-elementowych. W celu zmniejszenia rozmiarów sieci trzeciego rzędu wprowadzono okno, przesuwane po znaku na wejściu. Przetestowano trzy rozmiary okien: 16x16, 8x8 i 4x4. Wyniki rozpoznawania przedstawiono w tabeli 1.

Tabela 1

Rozmiar okna	Poprawne rozpoznania
16 na 16	98%
8 na 8	93%
4 na 4	86%

Jako klasyfikatora użyto także sieci back-propagation. Miała ona 32 węzły w warstwie wejściowej, jedną lub dwie warstwy ukryte (o różnych liczbach węzłów) i dziesięć węzłów w warstwie wyjściowej. Liczba poprawnych rozpoznań była jednak niższa o około 5% w stosunku do rezultatów otrzymanych dla klasyfikatora LVQ.

Zaproponowany system charakteryzuje się wysokim współczynnikiem poprawnych klasyfikacji. Sprawdzono, iż sieć neuronowa trzeciego rzędu, połączona z siecią LVQ, może dawać lepsze wyniki niż sieć back-propagation w zadaniach rozpoznawania cyfr. Ponadto czas „uczenia” zaproponowanego systemu jest znacznie krótszy niż dla sieci back-propagation.

4. Wykorzystanie sieci neuronowych do lokalizacji uszkodzeń w nieliniowych obwodach DC

Klasyczne podejście do diagnostyki uszkodzeń w obwodach analogowych, wykorzystujące metody symulacji przedtestowej, tzw. metody słownikowe, stanowi obiekt badań naukowych od ponad dwudziestu lat [14]. Głównymi problemami, jakie występują w tym podejściu, są: duży rozmiar przechowywanych danych, niejednoznaczność diagnozy związana z tolerancjami parametrów obwodu, przyjęcie właściwych kryteriów rozróżniania uszkodzeń oraz możliwość stosowania jedynie w przypadku pojedynczych uszkodzeń katastroficznych. Wykrywanie i lokalizacja uszkodzeń przy zastosowaniu metod słownikowych generalnie stanowi problem z dziedziny rozpoznawania obrazów. Ostatnio, do rozwiązywania tego problemu stosuje się nowe narzędzie, jakim jest sieć neuronowa. Proponuje się w związku z tym zastąpienie klasycznego słownika uszkodzeń siecią neuronową. To zastosowanie sieci neuronowej zaproponowano po raz pierwszy dla diagnostyki rozbudowanej instalacji chemicznej [15], lecz ze względu na swą specyfikę różni się ono znacznie od proponowanego. Główne różnice tkwią w charakterze danych wejściowych, sposobie ich pozyskiwania i przedstawiania. Proponując sieć neuronową w miejsce klasycznego słownika, poszukiwać będziemy odpowiedzi na następujące pytania.

- Czy słownik uszkodzeń można przedstawić w postaci sieci neuronowej?
- Czy sieć neuronowa uczona w pojedynczych uszkodzeniach katastroficznych posiada zdolności generalizacyjne, tzn. czy daje poprawną diagnozę w przypadku uszkodzeń parametrycznych lub wielokrotnych?
- Czy sieć neuronowa stawia właściwą diagnozę w przypadku zaszumionych danych wejściowych, w związku z tolerancjami parametrów obwodu?

Podobnie jak w innych pracach zajmujących się problemem diagnostyki uszkodzeń z wykorzystaniem sieci neuronowej [15] przyjęto, że siecią tą jest perceptron

wielowarstwowy z jedną warstwą ukrytą, sigmoidalnymi nieliniowościami neuronów i algorytmem uczącym typu „back-propagation” [2].

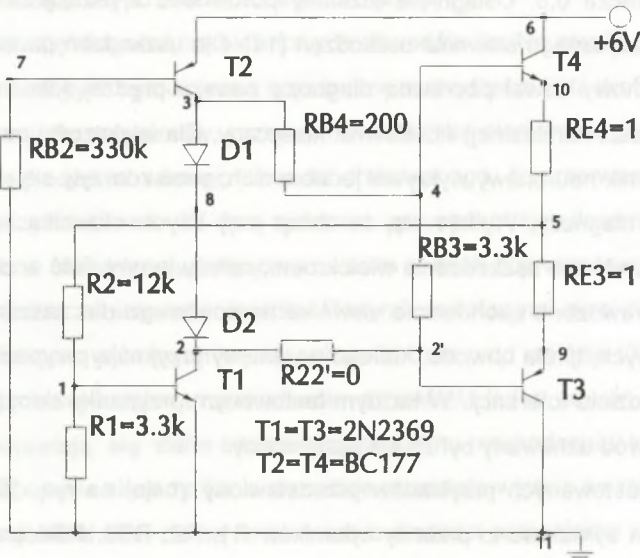
Zajmowano się diagnostyką nieliniowych obwodów dc. Na etapie przygotowania bazy danych uczących symulowano pojedyncze uszkodzenia katastroficzne elementów, tj. przerwy dla rezystorów, przerwy i zwarcia dla elementów półprzewodnikowych oraz uszkodzenia samego obwodu drukowanego, tj. przerwanie ścieżki lub zwarcie międzyscieżkowe. W tym ostatnim przypadku symulowano najbardziej prawdopodobne uszkodzenia, mając na uwadze sposób poprowadzenia druku i kierując się doświadczeniem inżynierskim. Danymi wejściowymi sieci neuronowej są potencjały węzłowe wybranych węzłów obwodu oraz prąd wejścia i/lub wyjścia. W warstwie wyjściowej każdemu uszkodzeniu odpowiada jeden neuron. Jeśli na wejściu sieci pojawiają się dane odpowiadające j-temu uszkodzeniu, to wówczas na j-tym wyjściu pojawia się jedynka, a wszystkie pozostałe wyjścia są równe zero. Założono, że wejściami sieci nie są bezpośrednio wartości potencjałów węzłowych czy prądu wejścia (wyjścia), lecz odchyłki od wartości otrzymanych w wyniku symulacji obwodu nieuszkodzonego (z nominalnymi wartościami wszystkich parametrów). W ten sposób, na etapie uczenia sieci, dla obwodu nieuszkodzonego wszystkie wejścia i wszystkie wyjścia przyjmują wartość równą zero, co stanowi sytuację pożądaną.

Wyniki symulacji komputerowej i wnioski

Przetestowano szereg przykładów, w tym przykłady z pracy [14]. Symulowano wybrane pojedyncze uszkodzenia katastroficzne. Założono liczbę neuronów warstwy ukrytej identyczną z liczbą neuronów warstwy wyjściowej, tj. z liczbą symulowanych uszkodzeń. Na etapie uczenia sieci (wykorzystano pakiet programów Neural Works Professional II) natrafiono na problemy w przypadku sieci, których pewne wejścia przyjmowały wartości z bardzo szerokiego zakresu. Dla poprawy rozdzielczości takich wejść zaproponowano nową technikę opisaną szczegółowo w pracy [13]. Po tym zabiegu, dla wszystkich testowanych przykładów, udało się nauczyć sieć rozpoznawania wszystkich uszkodzeń symulowanych na etapie przedtestowym. Skumulowany błąd wyjściowy mniejszy od 0,01 osiągnąć było średnio po 10 000 cykli uczących. By sprawdzić zdolności generalizacyjne sieci, testowano jej zachowanie dla wybranych uszkodzeń parametrycznych oraz uszkodzeń podwójnych. Na etapie

odwołania sieci założono, że wykryte zostało j -te uszkodzenie, jeśli wartość j -tego wyjścia przekracza 0,5. Osiągnięte rezultaty porównano z rezultatmi uzyskanymi przy użyciu klasycznego słownika uszkodzeń [14]. Dla uszkodzeń parametrycznych słownik neuronowy dawał poprawną diagnozę zawsze prędzej (dla mniejszej odchyłki od wartości nominalnej) niż słownik klasyczny. Dla większości uszkodzeń podwójnych słownik neuronowy wykrywał jedno z nich, choć zdarzyły się również przypadki błędnej diagnozy. Wydaje się, że chcąc przy użyciu słownika neuronowego diagnozować wybrane uszkodzenia wielokrotne, należy je umieścić w zbiorze uczącym sieci. Sprawdzono zachowanie słownika neuronowego dla zaszumionych danych wejściowych, tj. dla obwodu, którego parametry przyjmują przypadkowe wartości z 5% przedziału tolerancji. W każdym testowanym przypadku decyzja była właściwa, tzn. obwód uznawany był za nie uszkodzony.

Jeden z testowanych przykładów przedstawiony został na rys. 10. Na etapie przedtestowym symulowano przerwy oporników R1, R2, RB3, RB4 oraz przerwy i zwarcia diody i wszystkich tranzystorów (przerwa $\Rightarrow i_B=i_C=0$; zwarcie $\Rightarrow i_B=0$, $u_{CE}=0$). Założono, że dostępne pomiarowo są potencjały w węzłach 1,2,3,4,5 oraz prąd zasilania. Po dokonaniu symulacji 16 stanów obwodu (obwód nominalny + 15 stanów z uszkodzeniem pojedynczym) stwierdzono, że bez dodatkowych pomiarów nie można rozróżnić zwarcia diody od przzerwania ścieżki (uszkodzenia te dają identyczne sygnatury pomiarowe) podobnie jak przerwy R2 od przerwy T4, a przerwy T3 od obwodu nominalnego. Ponadto stwierdzono, że pomiary potencjałów w węzłach 3,4 są nadmiarowe. Zatem sieć neuronowa realizująca taki słownik uszkodzeń ma 12 wyjść i 4 wejścia. Liczbę wyjść można zmniejszyć kodując je, np. przy użyciu kodu Hamminga. W pracy [13] zaproponowano sposób na poprawienie rozdzielczości wejść. Po tych zabiegach liczba wejść wzrosła do 9, a liczba wyjść zmalała do 7, tzn. uzyskano pożądaną strukturę piramidalną.



Rys. 10. Przykładowy obwód
Fig. 10. Example circuit

Podsumowując, osiągnięte wyniki wydają się być bardzo interesujące. Wygląda na to, że dowolny słownik dc przedstawić można w postaci sieci neuronowej typu wielowarstwowy perceptron. Taka sieć posiada zdolności generalizacyjne, tzn. dla znacznych uszkodzeń parametrycznych (dla wartości parametru różniącej się od wartości nominalnej o więcej niż 50%) w większości testowanych przypadków osiągnano poprawną diagnozę, podobnie jak w przypadku zaszumionych danych wejściowych, w związku z tolerancjami parametrów. Podkreślić należy jeszcze jedną bardzo ważną zaletę słownika neuronowego. Jest nią wielka szybkość przetwarzania danych (w przypadku implementacji na sprzęcie umożliwiającym równoległe przetwarzanie danych), a co za tym idzie - wielka szybkość podejmowania decyzji, co z kolei w wielu zastosowaniach ma fundamentalne znaczenie.

5. Podsumowanie

W artykule przedstawiono uogólnienie algorytmu uczenia sieci neuronowej typu back-propagation wykorzystujące twierdzenie Tellegena. Algorytm ten pozwala na uczenie sieci neuronowych bez sprzężeń zwrotnych i stabilnych sieci ze sprzężeniami zwrotnymi z różniczkowalnymi funkcjami aktywacji. Artykuł zawiera także przykład użycia sieci neuronowych do klasyfikacji linii papilarnych. Zaproponowana metoda oparta na samoorganizującej się sieci Kohonena dała wysoki współczynnik poprawnych klasyfikacji. Także następane zaprezentowane zastosowanie sieci neuronowych do rozpoznawania cyfr charakteryzuje się dobrymi wynikami klasyfikacji. Kolejny przykład pokazuje sposób wykorzystania sieci neuronowej typu wielowarstwowy perceptron do lokalizacji uszkodzeń w nieliniowych obwodach dc. Osiągnięte wyniki dowodzą, iż dowolny słownik dc przedstawić można w postaci sieci neuronowej. Sieć taka posiada zdolności generalizacyjne i w większości testowanych przypadków daje poprawną diagnozę.

LITERATURA

1. Tyma G.: Generalization of backpropagation based on Tellegen's theorem. Proc. of Int. Conf. on Artificial Neural Networks, Brighton'92, pp. 105-108, 1992.
2. Rumelhart D., Hinton G., Williams R.: Learning internal representations by error propagation, ICS Report 8506, 1985.
3. Fettweis A.: A General Theorem for Signal-flow Networks, with Applications, AEU, Band 25, pp. 557-561, 1971.
4. Mościńska K., Tyma G.: Neural Network Based Fingerprint Classification, Third International Conference on Artificial Neural Networks, Brighton, UK, 1993.
5. Raczyński D., Skopiński Z.: Wywiad daktyloskopijny przez telefon, Wydawnictwo Zakładu Kryminalistyki KGMO, Warszawa 1961.
6. Mościńska K., Tyma G.: LVQ for fingerprint categorization, XVI-th National Conference on Circuit Theory & Electronic Circuit, Kołobrzeg 1993.
7. Pavlidis T.: Grafika i przetwarzanie obrazów, WNT, Warszawa 1987.
8. Wu R-Y., Tsa W-H.: A new one-pass parallel thinning algorithm for binary images, Pattern Recognition Letters, 1992.

9. Kohonen T.: Self-Organization and Associative Memory, Springer Verlag, 1989.
10. Tyma G., Mościńska K.: Digit Recognition Based on Neural Networks, XVI SPETO 1993, Ustroń, pp. 345-352, 1993.
11. Pao Y-H.: Adaptive Pattern Recognition and Neural Networks. New York: Addison Wesley, 1989.
12. Kohonen T.: Improved version of learning vector quantization. IJCNN-1990, San Diego, 1545-550, 1990.
13. Rutkowski G.: A Neural Network Approach to Fault Location in Nonlinear dc Circuits. Proc. of Int. Conf. on Artificial Neural Networks, Brighton'92, pp. 1123-26, 1992.
14. Bandler J.W., Salama A.E.: Fault Diagnosis of Analog Circuits, Proc. of IEEE, vol.73, Aug. 1985, pp. 1279-1325, 1985.
15. Hoskins J.C., Kaliyur K., Himmelblau D.: Fault Diagnosis in Complex Chemical Plants Using Artificial N.N., AIChE Journal, vol.37, Jan.1991, pp. 137-141, 1991.

Recenzent: Dr hab.inż. Tomasz Kacprzak

Wpłynęło do Redakcji 15.10.1994 r.

Abstract

This paper presents the results of our neural network research in the last few years. At first we propose generalization of the error backpropagation algorithm based on Tellegen's theorem. Due to generalization, learning method can be used for any feedforward network as well as a stable recurrent network with differentiable activation function. The following part presents the application of neural network for fingerprint classification. The proposed system allows to extract elementary fingerprint structures, which form the basis for the fingerprint classification into one of the following classes: arches, loops or whirls. The next part demonstrates the digit recognition system based on neural networks. A third order neural network and LVQ network have been used as a feature extractor and a classifier respectively. The proposed system has achieved high ratio of correct pattern classification. The last

part presents a neural network approach to fault location in nonlinear dc circuits. It has been shown that an arbitrary dictionary can be expressed in the form of a multi-layer network. Such a network has generalization ability, can accommodate its diagnosis to noisy input data and has great processing speed.

Instytut Elektroniki
Politechniki Śląskiej

ALGORITHMY SYMULACJI HYBRYDOWEJ

Streszczenie. Praca stanowi przegląd algorytmów różnych rodzajów symulacji mających zastosowanie w symulacji hybrydowej. Techniki symulacji dyskretnych i ciągłych zostały przedstawione pod kątem ich implementacji w symulatorach hybrydowych. Zamieszczone zostały przykłady dwóch konkretnych rozwiązań symulatorów hybrydowych. Praca bierze początkowo na dowiadzczeniach wyniesionych z prac w zakresie symulacji obwodów, prowadzonych od kilku lat w Instytucie Elektroniki Politechniki Śląskiej.

ALGORITHMS OF MIXED-MODE SIMULATION

Summary. In the paper an overview of different simulation techniques exploited in mixed-mode simulation is presented. Discrete- and continuous simulation are described in context of their use in the mixed-mode simulation. Detailed examples of two particular mixed-mode simulators are included. Some comments in the paper are based on the experience gained while dealing with network simulation at the Institute of Electronics of Silesian Technical University since a last few years.

ALGORITHMEN VON HYBRIDSIMULATION

Zusammenfassung. In diesem Aufsatz wird Übersicht von verschiedenen Simulationsalgorithmen, die in Hybridsimulation verwendbar sind, wird angegeben. Diskrete und stetige Simulation werden diskutiert als Beispiele für eine Hybridsimulation. Die Beschreibung von zwei praktischen Hybridsimulatoren wird eingeschlossen als ein Beispiel. Zum Teil basiert der Aufsatz auf einer Erfahrung mit der Simulation, gewonnen in letzten Jahren während der Arbeit im Institut für Elektronik an der Technische Universität von Copenshagen.