




POLSKA AKADEMIA NAUK
Instytut Badań Systemowych

**WSPOMAGANIE INFORMATYCZNE
ROZWOJU
SPOŁECZNO-GOSPODARCZEGO
I OCHRONY ŚRODOWISKA**

Redakcja:
Jan Studziński
Ludostław Drelichowski
Olgierd Hryniewicz





**WSPOMAGANIE INFORMATYCZNE
ROZWOJU
SPOŁECZNO-GOSPODARCZEGO
I OCHRONY ŚRODOWISKA**

Polska Akademia Nauk Instytut Badań Systemowych

Seria: BADANIA SYSTEMOWE

tom 36

Redaktor naukowy:

Prof. dr hab. Jakub Gutenbaum

Warszawa 2004

**WSPOMAGANIE INFORMATYCZNE
ROZWOJU
SPOŁECZNO-GOSPODARCZEGO
I OCHRONY ŚRODOWISKA**

Redakcja:

Jan Studziński
Ludosław Drelichowski
Olgierd Hryniewicz

Książka wydana dzięki dotacji KOMITETU BADAŃ NAUKOWYCH

Książka zawiera wybór artykułów poświęconych omówieniu aktualnego stanu badań w kraju w zakresie rozwoju modeli, technik i systemów zarządzania oraz ich zastosowań w różnych dziedzinach gospodarki narodowej. Wyodrębnioną grupę stanowią artykuły omawiające aplikacyjne wyniki projektów badawczych i celowych KBN.

Recenzenci artykułów:

Dr Lucyna Bogdan
Prof. dr hab. inż. Olgierd Hryniewicz
Dr Grażyna Petriczek
Prof. dr hab. inż. Andrzej Straszak
Dr inż. Jan Studziński



Senia 45187

Komputerowa edycja tekstu: Anna Gostyńska

© Instytut Badań Systemowych PAN, Warszawa 2004

Wydawca: Instytut Badań Systemowych PAN
ul. Newelska 6, 01-447 Warszawa

Sekcja Informacji Naukowej i Wydawnictw IBS PAN
tel. 836-68-22

Druk: Zakład Poligraficzny Urzędu Statystycznego w Bydgoszczy
Nakład 110 egz.

ISBN 83-85847-92-8
ISSN 0208-8028

KIERUNKI INTEGRACJI TECHNOLOGII INFORMACYJNYCH W ZARZĄDZANIU WIEDZĄ W PRZEDSIĘBIORSTWIE

Ludostaw Drelichowski, Ryszard Wojtyna, Waldemar Bojar

Akademia Techniczno Rolnicza w Bydgoszczy

<lu.drel@atr.bydgoszcz.pl>

The paper presents recent trends in information technologies applied to enterprise management. Both expert systems and artificial neural networks as two main groups of artificial intelligence are discussed. Problems of integrating different technologies under typical enterprise conditions are considered. The paper emphasizes the necessity of combining software with hardware tools to improve effectiveness of information processing. New possibilities of implementing artificial intelligence in hardware are indicated and issues associated with adaptive learning on silicon clarified.

Keywords: Management Information System development trends, Expert System constraints, Artificial Neural Network development.

1. Wstęp

Ekspansja publikacji podejmujących problematykę zarządzania wiedzą stanowi naturalny efekt rozwoju technologii przetwarzania informacji (IT–*Information Technology*) występującej w skali globalnej. Jest to obserwowane w skali poszczególnych ugrupowań międzynarodowych UE, CEFTA, NAFTA oraz w skali poszczególnych krajów, przedsiębiorstw bądź ich grup. Szczególnie często spotkać można rozważania podejmujące różnorakie teoretyczne aspekty zarządzania wiedzą, które mają istotne znaczenie dla tworzenia uogólnień problemu i często są kłopotliwe do ich aplikacyjnej interpretacji.

Identyfikacja poziomu zaawansowania technologii informacyjnych upoważnia do określenia stanu pozwalającego stwierdzić efektywne wspomaganie zarządzania wiedzą. Syntetyczna ocena takiego stanu zaawansowania musi uwzględniać z jednej strony poziom technologii informacyjnych wdrożony do obsługi procesów biznesowych, a z drugiej zakres pozyskiwania i przetwarzania baz danych poprzez tworzenie hurtowni danych oraz jej automatyczne analizy (OLAP lub *data mining*), sprzyjające tworzeniu dziedzinowych baz wiedzy. Propozycje identyfikacji poziomu zaawansowania technologii informacyjnych w zarządzaniu wiedzą prezentuje (Olszak, 2001), przyjmując dążenie do zastosowań możliwie wielu standardów jako przesłankę decydującą o standardach jakościowych. Podejście to dostępne jest przede wszystkim dla dużych i wielkich przedsiębiorstw posiadających zasoby finansowe umożliwiające dokonanie zakupu nowych

technologii informacyjnych. (Perechuda, 2003) prezentuje bardziej zaawansowane teoretycznie podejście do infrastruktury informacyjnej wspomagania zarządzaniem wiedzą, jako sieciowych procesów dyfuzji wiedzy, uwzględniających specyficzne potrzeby elastycznie definiowanych organizacji wirtualnych. W pracy tej autor wprowadza aparat pojęciowy umożliwiający określanie wzajemnych uwarunkowań zasilania wiedzą struktur sieciowych, których formę przybierać mogą organizacje wirtualne, ze szczególnym wyekspozowaniem kluczowego znaczenia pozyskiwania wiedzy dynamicznej.

2. Procesy integracji środowisk technologii informacyjnych w sterowaniu procesami ciągłymi i przetwarzaniu danych

W przedsiębiorstwach realizujących procesy ciągłe w technologiach wytwarzania (np. przemysł aparaturowy), pojawiają się specyficzne strumienie danych i procedury sterowania *on-line*, które mają bezpośredni wpływ na jakość i wydajność sterowanych procesów. Nowoczesne instalacje produkcyjne wyposażane są zwykle w standardowy *interface* niezbędny do zasilania raportami z realizacji procesów baz danych przedsiębiorstwa. W odniesieniu do nowych inwestycji powyższe stwierdzenia są w pełni uzasadnione, jednak dobudowywane w miarę upływu lat nowe instalacje nie zawsze są kompatybilne z wcześniej montowanymi. Różne procesy dostosowawcze i dążenie do wykorzystania nowych fragmentów zmieniających procesów technologicznych powodują, że wykorzystując wiedzę pracowników, projektowane są własne instalacje, a wraz nimi również niestandardowe systemy sterowania.

Tworzenie baz danych z odczytów dynamicznych przyrządów pomiarowych zapewnia możliwość ich różnorodnej agregacji i poddania procedurom automatycznej analizy. W praktyce przetwarzania informacji w tego typu obiektach stosowane są zdublowane systemy raportowania z automatycznych czytników i raportów sporządzanych w pionie produkcji. Ten system pozwala zidentyfikować pojawiające się usterki, jako odchylenia parametrów, zanim ujawni się niekorzystna w skali oddziaływania na efektywność niższa jakość bądź wydajność produktów. Uzasadnione jest w takich przypadkach włączenie do procesów kontroli i raportowania mikroprocesorów zawierających dedykowane oprogramowanie *hardware'owe*, umożliwiające tworzenie raportów oraz sygnalizowanie różnorodnych odchylen występujących w analizie dynamicznej kontroli procesów aparaturowych.

W tym przypadku mamy do czynienia z mechanizmem kreowania wiedzy o przebiegu procesów i automatycznej diagnostyce zagrożeń ich desynchronizacji. Bardzo ważnym elementem występującym w realizacji tego typu zautomatyzowanych procedur kontrolnych procesów produkcyjnych jest spełnienie warunku zachowania autonomii poszczególnych strumieni informacyjnych, których równoległe funkcjonowanie zapewnia wyższy poziom niezawodności. Nadzór nad sprawnością danego nośnika strumieni kontrolnych musi być powierzony służbom

produkcyjnym, które muszą współuczestniczyć w opracowaniu modelu sprzężeń zwrotnych występujących pomiędzy dwoma równoległymi systemami informacyjnymi. Przytoczony w ostatnich zdaniach fragment analizy eksponuje psychologicznie wysoką rangę określonych strumieni informacyjnych i próba ich uproszczenia będzie miała negatywne skutki, o czym świadczy występowanie wysoce nadmiarowych rozwiązań w mózgu człowieka.

Powyższa analiza wykonywana była na podstawie realnych rozwiązań technologii informacyjnych, stosowanych w dużym zakładzie międzynarodowej korporacji, opartych o system zintegrowany, hurtownię danych i złożone systemy sterowania procesami technologicznymi. Właśnie w tej organizacji na uwagę zasługuje strategia oszczędności nakładów kosztem nowoczesności i elegancji rozwiązań dostarczanych przez globalnych producentów technologii *know-how*, droższych od rozwiązań własnych dwu-, a nawet trzykrotnie. Z przytoczonych rozważań wynika, jak wielowątkowo musi być postrzegana nowoczesność także w formułowaniu celów zarządzania wiedzą, aby nie tracić eksponowanych w łańcuchu wartości Portera (Porter, 1985) przewag konkurencyjnych, wynikających z ograniczenia kosztów zakupu zasobu.

3. Uwarunkowania i ograniczenia zastosowania metod sztucznej inteligencji w praktyce gospodarczej

Jednym z proponowanych podejść do rozwiązywania problemów decyzyjnych w przedsiębiorstwach jest zastosowanie metod sztucznej inteligencji (AI). Stosowanie sztucznej inteligencji jest rozwiązaniem niosącym w praktyce wymierne korzyści, ponieważ:

- jest o wiele tańsze niż włączenie ekspertów do rozwiązywania problemów,
- jest niezależne od ekspertów, gdyż raz zgromadzona wiedza w pamięci komputera może być przechowywana i wielokrotnie wykorzystywana w zakresie zagadnień i problemów danej klasy,
- jest o wiele szybsze niż praca ekspertów,
- może uwzględniać usprawnienia w zakresie posiadanej wiedzy SI, podczas gdy wiedza ludzka może być obciążona błędem, przy każdorazowym jej stosowaniu,
- zezwala na udokumentowanie wiedzy, w odróżnieniu od wiedzy człowieka, ze względu między innymi na jego psychologiczne cechy (emocje, zmiany poglądów, postawy, itp.),
- może wspierać określone prace w bardziej efektywny sposób niż to czynią ludzie (Flakiewicz, 2002).

W początkowym okresie rozwoju metod AI ukształtowały się dwa różne podejścia do założeń teoretycznych tej klasy rozwiązań IT.

Według Gillies'a (1994) podejście psychologiczne Simon'a i jego grupy do sztucznej inteligencji jest próbą stymulowania indukcyjnych metod wnioskowania i poglądów znanych naukowców w celu odkrycia nowych prawidłowości funkcjonowania maszyny. Okazało się, że opinie znanych naukowców są zjawiskiem bardzo skomplikowanym, niemożliwym do zanalizowania przy pomocy prostych metod wnioskowania (stąd słabe rezultaty zastosowania takiego podejścia w praktyce).

Z drugiej strony podejście logiczne do AI oparte na ideałach Turinga wraca obecnie do pierwotnych idei tego badacza, pozwalając łączyć logikę i praktykę. Celem takiego podejścia jest opracowanie ogólnych reguł indukcyjnych przy wykorzystaniu praw logiki i teorii prawdopodobieństwa dla dokonania istotnych odkryć za pośrednictwem maszyn.

W systemach sztucznej inteligencji można wyróżnić dwie zasadnicze grupy narzędzi: systemy ekspertowe i sieci neuronowe. Na etapie opracowania teorii wydawało się, że obydwa podejścia mogą być bardzo obiecujące w obszarze wspomaganie decyzji z uwagi na nowe możliwości, których dostarczały narzędzia sztucznej inteligencji. Próby wdrożenia do praktyki zarządzania nowych technologii komputerowych napotkały na bariery zawężające obszar możliwych zastosowań. Według Sigrimsa i in. (1999) metody sztucznej inteligencji nie zajęły tak dominującej pozycji w systemach informacyjnych zarządzania, jak się tego wcześniej spodziewano, jednak poczynione zostały znaczące kroki w ich stałej obecności w systemach wspomaganie decyzji (SWD). Wiele z opracowanych metod, np. Sztuczne Sieci Neuronowe (ANN), rozmyte Systemy Bazy Wiedzy (f-KBS) uzyskały szeroką akceptację w aplikacjach wspomaganie użytkownika, kontroli i zarządzania. Systemy ekspertowe wykorzystują indukcyjne reguły wnioskowania, np. system IRIS opiera się na wzorcu bazującym na K i e , gdzie K jest wiedzą podstawową, e jest dowodem lub daną, a H jest hipotezą sformułowaną w celu wyjaśnienia e przy użyciu K . Systemy te zostały zastosowane w IRIS iteracyjnie.

Pierwsza generacja systemów ekspertowych dotyczyła tylko rozpoznania i eliminacji złego funkcjonowania maszyn. Natomiast druga generacja systemów ekspertowych (Bartnik, i in. (2000) pozwala na głębokie przedstawienie konkretnej dziedziny, a modele należące do tej generacji pozwalają lepiej strukturyzować problemy. Istnieją dwa podejścia. Pierwsze-ontologiczne, które posiada 2 poziomy: pierwszy przybliża wyjaśnienie elementów i powiązań między nimi, czyli wyjaśnia fizyczną strukturę, co oznacza, że wyniki tych systemów mogą być niezrozumiałe jako grupa powiązanych elementów. Drugi poziom wyjaśnia funkcjonowanie danego systemu ekspertowego, co wymaga z zakresu praw i prawidłowości rządzących daną dziedziną, np. z zakresu ekonomiki rolnictwa, techniki rolniczej, agronomii, itp. W semantycznym podejściu wiedza w takim systemie jest podzielona na mniejsze grupy, a głównym powodem istnienia konfliktów są powiązania pomiędzy tymi grupami. Tego typu modele mniej wyjaśniają, ale

pozwalają lepiej strukturyzować problemy. Czasami ważniejsze od szczegółowych rozwiązań modelu jest dla podejmujących decyzje lepsze zobrazowanie problemu przez modele SWD. Według Adelmiana (1991) SWD jest zdywersyfikowaną klasą technologii komputerowej, integrującą informacje z baz danych i analityczne metody modelowania (sztuczna inteligencja, analiza decyzyjna, modele optymalizacyjne). Miarą skuteczności wykorzystania metod AI w praktyce jest m.in. ich efektywne zastosowanie w systemach wspomagania decyzji (SWD). Systemy ekspertowe będące immanentną częścią systemów wspomagania decyzji nie stanowią panaceum na rozwiązanie wszelkich problemów decyzyjnych, ponieważ ich przydatność jest ograniczona zakresem bazy wiedzy i reguł wnioskowania, które składają się na system, a które często z różnych przyczyn nie mogą uwzględnić wszystkich uwarunkowań rozwiązania danego problemu.

Podjęcie decyzji z zakresu planowania strategicznego (Haouche, Lamsade, 1993), a do takich należy planowanie inwestycji zakupu maszyn w gospodarstwach rolnych, jest zbyt złożone, żeby mogło być wspomagane metodami konwencjonalnymi. Według Simona'a (1983) tego typu problemy (planowania strategicznego) są z natury rzeczy źle ustrukturyzowane. Planowanie takie obejmuje dekompozycję głównego problemu na podproblemy, uruchomienie procesu wnioskowania na poziomie podproblemu, a następnie ich skoordynowanie i zagregowanie dla uzyskania globalnego rozwiązania. (teoria multi-agentów). Zastosowanie teorii multi-agentów pozwala użytkownikom systemu rekomendować plan akcji, a jeśli działania podejmowane w jej ramach są niekompatybilne, system udziela wyjaśnień użytkownikowi i poszukuje następnych sytuacji, które proponuje mu ponownie. Uzasadnieniem takiego rozwiązania do problemów strategicznych o złożonej strukturze jest teoria rozdzielczości i teoria konfliktu March'a i Simona (Simon, 1983).

W obszarze zastosowań systemów ekspertowych w SWD realną barierą okazał się również proces tworzenia dziedzinowej bazy wiedzy, którą należy najpierw zbudować, aby zinterpretować problemy decyzyjne na podstawie wprowadzonych reguł wnioskowania. Proces kreowania dziedzinowej bazy wiedzy jest pracochłonny i kosztowny (Bojar, 2003). Dla ujęcia wąskiego problemu decyzyjnego, np. z obszaru wyboru maszyn w gospodarstwach rolnych, konieczne jest stworzenie bardzo rozległej bazy wiedzy zawierającej dużą liczbę danych pochodzących z różnych źródeł i dziedzin wiedzy. Dane takie muszą obejmować parametry ekonomiczne, np. ceny maszyn, ceny energii elektrycznej, stopy procentowe, jak również parametry techniczno-eksploatacyjne determinujące wydajność i jakość pracy maszyn, a także ekspertyzy i opinie odnośnie ich trwałości, przydatności, wad i zalet. Wykonanie tak dużego zadania może stwarzać trudności pojedynczym osobom, instytucjom, lub organizacjom z powodu wysokich nakładów finansowych i pracochłonności takiego przedsięwzięcia. Problemem może być wówczas znalezienie rzeczywistych odbiorców rezultatów tak dużego projektu. Dlatego też, jak dotąd, opracowane systemy ekspertowe są wykorzystywane

w niektórych dziedzinach, np. w medycynie, a rzadziej w systemach informacyjnych zarządzania.

Z drugiej strony, sztuczne sieci neuronowe (Artificial Neural Networks - ANN) ujawniły duże możliwości w przetwarzaniu danych pochodzących z przedsiębiorstw. Komputery zaczęły być stosowane nie tylko w procesie uczenia sieci, ale także do ich implementacji w różnorodnych programach komputerowych. Taki kierunek rozwoju technologii informacyjno-komunikacyjnej pozwala niekiedy bardziej efektywnie rozwiązywać problemy decyzyjne niż metody algorytmiczne. Dla rozwiązywania innych problemów zarządzania wspomaganie procesu podejmowania decyzji przy pomocy ANN okazało się mniej efektywne. Jedną z przyczyn jest zbyt wolne tempo raportowania. Takie bariery zaobserwowano przede wszystkim w wielkich informacyjnych systemach transakcyjnych, gdzie ogromna liczba danych musi zostać przetworzonych w jednostce czasu (Drelichowski, 2004). Co więcej, równoległe do wdrażania coraz bardziej zaawansowanych, zintegrowanych systemów informacyjnych zarządzania przedsiębiorstwami (ERP2, CRM, SCM) i wzrastającymi potrzebami menedżerów na szybki dostęp do pożądanej informacji, liczba podstawowych operacji w sieciach neuronowych także bardzo szybko wzrasta. W rezultacie działanie sieci neuronowych opóźnia pozyskiwanie niezbędnych informacji wyjściowych. W opinii Wojtyny (2003) przyczyną wolniejszego tempa przetwarzania danych w ANN może być zbyt mała pojemność sztucznych sieci neuronowych w porównaniu do sieci biologicznych funkcjonujących w ludzkim mózgu. Z tego powodu proces uczenia się, przebiegający równoległe do przepływu impulsów w ludzkim mózgu (nie ma rozdziału na fazę uczenia sieci i fazę odtwarzania, jak to ma miejsce w ANN), nie może być realizowany tak szybko w sieciach sztucznych. Obecnie w tym obszarze pojawiły się nowe możliwości z powodu nanotechnologii opartej na układach scalonych dużej skali integracji. Jedną z możliwości przyspieszenia tempa raportowania w systemach wspomaganie decyzji było wykorzystanie sieci neuronowych zaimplementowanych w układach scalonych. Sieci takie działają bardzo szybko i mogą wykonywać określone zadania, ale nie mogą „się uczyć”. W 1999 roku Cauwenberghs’a i Bayoumi (1999) opracowali nową metodykę opartą na nanotechnologii, pozwalającą realizować proces uczenia w układach krzemowych działających podobnie do sieci biologicznych. Warunkiem umożliwiającym realizację takich inteligentnych, samouczących się układów scalonych było opracowanie energooszczędnych układów analogowych wzorowanych na zasadzie działania układów biologicznych (Wojtyna, 2003).

4. Kierunki rozwoju sztucznej inteligencji wzorowanej na naturze

Jak już wspomniano, sztuczną inteligencję można podzielić na systemy ekspertowe, nierozzerwalnie związane z techniką komputerową i sztuczne sieci neuronowe ANN. Sieci ANN są najczęściej implementowane również na komputerze w formie odpowiednich programów, ale pojawia się coraz więcej realizacji sprzętowych takich sieci. Implementacja sprzętowa może polegać na

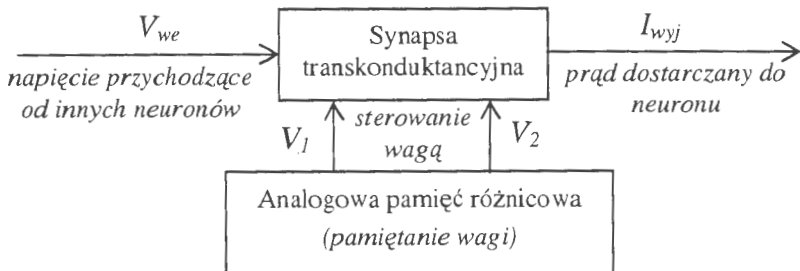
realizacji programu zapisanego w odpowiednich pamięciach ROM z wykorzystaniem elektronicznych układów cyfrowych. W takim przypadku sposób działania sieci w zasadzie niewiele różni się od działania typowego programu komputerowego, zapisanego w pamięci operacyjnej. Wyższość realizacji sprzętowej sprowadza się wówczas to szybszego wykonywania programu, ponieważ może on być prostszy, wiele operacji sekwencyjnych może być zastąpionych operacjami o charakterze kombinacyjnym, a realizowane działania sekwencyjne mogą być szybsze, jako że wszystko odbywa się wewnątrz układu scalonego. Sprzętowe sieci tego typu oraz sieci implementowane jako programy komputerowe będziemy dalej nazywać sieciami konwencjonalnymi. W obu przypadkach mamy do czynienia z symulacją działania sieci neuronowych, opartą na odpowiednich modelach, która dosyć istotnie różni się od pierwowzoru biologicznego. Obserwowana na przestrzeni około sześćdziesięciu lat ewolucja sieci konwencjonalnych coraz bardziej oddalała się od zjawisk obserwowanych w neurobiologii. Rozwój sieci ANN wynikał bardziej z szybko rosnących możliwości techniki komputerowej niż z rozwoju wiedzy na temat sieci biologicznych. Zaletą tak realizowanych, sprzętowych implementacji sieci są relatywnie proste interfejsy sprzęgające sieć z komputerem. Ułatwia to współpracę sprzętowych modułów sieci z systemami ekspertowymi i innymi systemami komputerowego przetwarzania informacji. Mimo zalet sieci konwencjonalnych, prowadzone są badania nad stworzeniem sieci ANN bardziej zbliżonych w działaniu do sieci biologicznych, wykazujących wyższy stopień inteligencji niż rozwiązania stosowane dotychczas, zarówno sprzętowe, jak i czysto programowe. Poszukuje się i udoskonala rozwiązania realizowane w formie układu scalonego dużej skali integracji VLSI (*Very Large Scale of Integration*), wykazujące zdolność do szybkiego, adaptacyjnego uczenia się w krzemie (*on chip learning*).

Cechą wspólną konwencjonalnych sieci ANN jest występowanie dwóch oddzielnych faz ich pracy, tj. fazy uczenia i fazy odtwarzania. Konieczność podziału na fazę uczenia i fazę odtwarzania wynika z faktu, że proces uczenia takich sieci jest generalnie bardzo długi, za długi, by można było to robić w fazie odtwarzania. Gdy do powszechnego użytku weszły komputery, proces uczenia sieci ANN zaczął być wykonywany na komputerze i ten fakt istotnie wpłynął na kierunek dalszego rozwoju tych sieci. Podział na fazę uczenia i odtwarzania nie występuje w naturze. Sieć biologiczna uczy się także, a często głównie w trakcie pracy. Jest to jedna z zasadniczych różnic między sieciami biologicznymi i ich sztucznymi odpowiednikami. Druga różnica polega na wielkości tych sieci. Wiadomo jest, że tajemnica pracy inteligentnej sieci biologicznej wynika między innymi z jej ogromu. O ile potrafimy z lepszym lub gorszym skutkiem zamodelować pracę neuronu, to znacznie gorzej jest z realizacją sieci bardzo dużej. W przypadku implementacji czysto komputerowej trudności ze zwiększaniem liczby neuronów i liczby warstw sieci wynikają przede wszystkim ze stosowanych metod ich uczenia. Po przekroczeniu pewnej granicy, dalsze zwiększanie rozmiarów sieci nie daje pożądanego efektu w postaci lepszego lub szybszego jej działania. Przy sprzętowej realizacji, warunkiem koniecznym zbudowania bardzo dużej sieci jest opracowanie

energooszczędnej, analogowej elektroniki do realizacji podstawowych operacji w sieci. Dopiero ostatnie osiągnięcia mikro- i nanotechnologii uczyniły to zadanie realizowalnym.

Badania prowadzone w wielu ośrodkach naukowych skupiają się ostatnio nad problemem nazywanym adaptacyjnym uczeniem w krzemie (*adaptive learning on silicon*). Chodzi o sprzętową realizację sieci zdolnej do szybkiego uczenia się w trakcie pracy (w fazie odtwarzania). Można wyróżnić trzy podstawowe typy sieci, w których jest to możliwe. Pierwszą grupę stanowią tzw. sieci neuronowe komórkowe CNN (*Cellular Neural Network*). W sieci CNN neuron, zwany komórką, współpracuje tylko z najbliższym sąsiedztwem. W efekcie połączenia między neuronami mają tylko charakter lokalny. Sieci te mają ponadto ujednocioną strukturę, a sąsiedztwo każdego neuronu, oprócz neuronów brzegowych, jest jednakowe. Uczenie sieci jest z tego powodu ułatwione i sprowadza się do ustalenia architektury połączeń i sposobu współpracy neuronu z neuronami należącymi do jego sąsiedztwa. Sieci CNN są jednak mniej uniwersalne od innych sieci ANN i są głównie wykorzystywane do przetwarzania obrazów (Rosca, 2001). W odróżnieniu od dwóch pozostałych typów sieci VLSI zdolnych do adaptacyjnego uczenia w krzemie, sieci CNN nie są próbą wierniejszego naśladowania natury, lecz uproszczenia ich struktury i metod projektowania.

Innym typem sieci odpowiedniej do adaptacyjnego uczenia wewnątrz układu scalonego są sieci z neuronami impulsowymi (*Pulsed Neural Networks* lub *Networks of Spiking Neurons*) (Maass, 1999). Są to sieci bazujące na dokładniejszym modelu neuronu, uwzględniającym nie tylko zjawiska statyczne, jak ma to miejsce w sieciach konwencjonalnych, ale także relacje czasowe między impulsami przesyłanymi w sieci. Model ten jest wierniejszą kopią funkcjonowania neuronów biologicznych. Implementacja sprzętowa takich sieci jest jednak trudniejsza niż implementacja sieci opartych na modelu statycznym.



Rysunek 1. Schemat blokowy synapsy sterowanej napięciem różnicowym przystosowanej do adaptacyjnego uczenia w krzemie

Czymś pośrednim pod względem stopnia złożoności zarówno architektury sieci jak i metod uczenia są sieci oparte na klasycznym, statycznym modelu neuronu, rozbudowanego o lokalną pamięć analogową, usytuowaną przy każdej synapsie. Obecność pamięci lokalnej przy synapsie jest również bardzo pożądana w wymienionych wcześniej typach sieci neuronowych zdolnych do adaptacyjnego uczenia w krzemie. Na rys. 1 przedstawiono schematycznie synapsę transkonduktansyjną, współpracującą z różnicową pamięcią analogową. Różnicowy sposób pamiętania informacji zwiększa precyzję tej operacji i tym samym precyzję sterowania wartością wagi połączenia synaptycznego.

Sygnałem wejściowym synapsy jest napięcie V_{we} , ponieważ transmisja sygnałów napięciowych oznacza małe straty mocy w ścieżkach łączących neurony. Sygnał wyjściowy synapsy jest natomiast prądem, I_{wyj} , ponieważ prądy można wygodnie sumować w jednym węźle sieci (na wejściu właściwego neuronu). Oznacza to, że synapsa pracuje w trybie transkonduktancyjnym, natomiast neuron w trybie transrezystancyjnym.

Obecność pamięci analogowej wewnątrz układu scalonego umożliwia szybkie uczenie w fazie odtwarzania sieci. Rozwiązanie z pamięcią cyfrową zlokalizowaną na zewnątrz układu scalonego nie nadaje się do tego celu, ponieważ komunikacja między nią a węzłami sieci musiałaby się odbywać w sposób multipleksowany, co trwa bardzo długo, tym dłużej im większa sieć. Zlokalizowanie dużej liczby pamięci cyfrowych wewnątrz układu scalonego przy synapsach oznacza konieczność realizacji wielu przetworników analogowo-cyfrowych i cyfrowo-analogowych, które zajmują w krzemie dużo miejsca i nie pozwalają zbudować dużej sieci. Jedyne rozsądne rozwiązanie to opracowanie małych pamięci analogowych umieszczonych przy każdej synapsie. W tym zakresie istnieje również kilka możliwości. Mogą to być pamięci oparte na urządzeniach z izolowaną bramką (*floating gate devices*), na pamięciach statycznych z zatraskowym mechanizmem trzymania informacji, tak jak w pamięciach cyfrowych SRAM, oraz na pamięciach dynamicznych, w których informacja jest trzymana w formie ładunku na kondensatorze, podobnie jak w pamięciach cyfrowych DRAM. Dla potrzeb szybkiego uczenia w krzemie, najlepszą jak dotąd okazuje się być pamięć dynamiczna. Jej wadą jest wprawdzie stosunkowo krótki czas trzymania informacji, ale problem ten można złagodzić albo przez odświeżanie pamięci, albo wprowadzenie kluczowanego sprzężenia zwrotnego w celu redukcji prądów upływu związanych z kluczami CMOS. Odświeżanie pamięci analogowej jest dużo trudniejsze niż odświeżanie pamięci cyfrowych DRAM. Bardziej obiecujące są prace nad zastosowaniem sprzężenia zwrotnego. Oryginalne rozwiązanie pamięci analogowej z kluczowanym sprzężeniem zwrotnym, przedstawione w pracy (Wojtyna, 2003), zostało pozytywnie zweryfikowane eksperymentalnie na prototypowych układach scalonych wykonanych w ramach organizacji EUROPRACTICE.



5. Wnioski

Wzrastające zapotrzebowanie na precyzyjną i szybko dostępną informację przydatną w zarządzaniu przedsiębiorstwami napotyka na rozliczne bariery organizacyjno-techniczne i technologiczne. W wielkich korporacjach takim ograniczeniem jest ogromna liczba danych, które należy przetworzyć w jednostce czasu dla uzyskania odpowiednich zestawień wynikowych dla menedżerów w odpowiednio krótkim czasie. Bariery są tutaj rozwiązania technologii komunikacyjno-informacyjnej (ICT), w tym transfer danych w sieci, które nie pozwalają spełnić oczekiwań menedżerów w tym zakresie.

Z drugiej strony jednostki mniejsze, oczekujące na instrumenty uniwersalne w procesie wspomagania decyzji, jak np. systemy ekspertowe, nie zawsze mogą z takich systemów skorzystać, bo trudno opracować i eksploatować dziedzinowe bazy wiedzy. Przyczyn trudności w tym zakresie należy poszukiwać zarówno po stronie potencjalnych twórców jak i odbiorców takich systemów, gdzie można zaobserwować brak odpowiedniej współpracy i koordynacji, aby takie systemy opracować i wdrożyć do praktyki.

Obiecującym podejściem dla złagodzenia ww. ograniczeń wydają się być najnowsze rozwiązania ICT oparte na rozwoju metod sztucznej inteligencji wzorowanych na naturze, a wykorzystujących osiągnięcia nanotechnologii i adaptacyjnego uczenia się w krzemie.

Literatura

- Adelman L. (1991) Experiments, quasi-experiments and case studies: a review of empirical methods for evaluating decision support systems. *IEEE Transactions on Systems, Man and Cybernetics*, 21, 2, 293-301.
- Bartnik G., Kusz A., Marciniak A.W. (2000) Probabilistic expert systems modelling breakdowns procedures. Operational Dependability of Machines'2000, w: *Proceedings of International Conference Prague, June 2000*, Czech university of Agriculture in Prague, 10-14.
- Bojar W. (2003) Dydaktyczne i badawcze aspekty zastosowania metod sztucznej inteligencji w procesach wspomagania decyzji w rolnictwie. *Prace Naukowe Akademii Ekonomicznej we Wrocławiu*, 975, Wyd. AE im. O. Langego we Wrocławiu, Wrocław, 23-34.
- Cauwenberghs G., Bayoumi M. (1999) *Learning on silicon, adaptive VLSI neural systems*. Kluwer Academic Publishers.
- Drelichowski L. (2004) *Podstawy Inżynierii Zarządzania Wiedzą*. Polskie Stowarzyszenie Zarządzania Wiedzą, Bydgoszcz, 110-118, 132.
- Flakiewicz W. (2002) *Systemy informacyjne w zarządzaniu (uwarunkowania, technologie, rodzaje)*. Wyd. C.H. Beck, Warszawa, 140-141.
- Gillies D. (1994) A Rapprochement between deductive and inductive logic. *Bulletin of the IGPL*, 2, 2, 149-166.

- Haouche C., Lamsade I. (1993) *Using a Conceptual Model to Validate KBS*. EUROV VV, 161-173.
- Maass W., Bishop Ch. M. (1999) *Pulsed Neural Networks*. The MIT Press, Massachusetts.
- Olszak C.M. (2001) Systemy informacyjne w zarządzaniu wiedzą w przedsiębiorstwach *Organizacja i Kierowanie*, 4, 75-87.
- Perechuda K. (2003) Model „pajęczyny” w dyfuzji wiedzy w organizacji. *Prace naukowe AE*, 986, 336-345, Wrocław.
- Porter M.E. (1985) *Competitive strategy. Techniques for Analyzing Industries and Competitors* The Free Press. A Division of Macmillan, INC. New York.
- Roska T., Rodrigues-Vazquez A. (2001) *Towards the Visual Microprocessor VLSI Design and the Use of Cellular Neural Network Universal Machines*. John Willey & Sons.
- Sigrimis N. et al. (1999) Prospects in Agricultural Engineering in the Information Age: Technological Developments for the Producer and the Consumer. *Agricultural Engineering International: the CIGR Journal of Scientific Research and Development*, Invited Overview Paper, I, December, 1999.
- Simon H.A. (1983) Search and reasoning in problem solving. *Artificial Intelligence*, 21(1-2), 7-29.
- Wojtyna R. (2003) Sprzętowa realizacja adaptacyjnych sieci neuronowych. Hardware realization of adaptive neural networks, in: *Application of Computing and system Analysis in Management*, Polish Academy of Sciences Systems Research Institute, Warsaw 2003.

IBS PAN *Seria*

45187

Bibl. podręczna

ISSN 0208-8028

ISBN 83-85847-92-8

**W celu uzyskania bliższych informacji i zakupu dodatkowych egzemplarzy
prosimy o kontakt z Instytutem Badań Systemowych PAN
ul. Newelska 6, 01-447 Warszawa
tel. 837-35-78 w. 241 e-mail: biblioteka@ibspan.waw.pl**