

USING OF NEURONAL TECHNIQUES IN AGRICULTURAL PRACTICE

S u m m a r y

The development of computer technologies caused the appearance of the completely new analytic possibilities, basing on observations of natural processes, and in peculiarity on conclusions following with scientific researches relating the brain work investigations, what is described by the dynamically developing techniques of neuronal processing. One should underline, that artificial neuronal networks are able to operate both on gatherings of numeric data coming from experimental investigations, as well as on fuzzy sets, so characteristic for perception of human mind. Recently they are used in agriculture in classification systems.

WYKORZYSTANIE TECHNIK NEURONOWYCH W PRAKTYCE ROLNICZEJ

S t r e s z c z e n i e

Rozwój technologii informatycznych spowodował pojawienie się zupełnie nowych możliwości analitycznych, bazujących na obserwacjach procesów naturalnych, a w szczególności na wnioskach płynących z badań naukowych dotyczących pracy mózgu, jakie opisują dynamicznie rozwijające się techniki przetwarzania neuronowego (Osowski S., 2000). Należy podkreślić, że sztuczne sieci neuronowe potrafią operować zarówno na zbiorach danych numerycznych, pochodzących np. z badań doświadczalnych, jak również na zbiorach rozmytych, tak charakterystycznych dla postrzegania ludzkiego umysłu. Ostatnio znajdują zastosowanie w systemach klasyfikacyjnych wykorzystywanych w rolnictwie.

Wstęp

Pojawienie się komputerów w latach czterdziestych XX wieku doprowadziło w konsekwencji do istotnego rozwoju nowoczesnych technik wspomagających metody przetwarzania szeroko rozumianej informacji. Od tamtego czasu komputer był również wykorzystywany jako narzędzie do symulowania złożonych problemów naukowych, takich jak np. badanie oraz analiza pracy mózgu. Eksperymentem symulacyjnym poddano działanie zarówno pojedynczego neuronu jak i całej grupy neuronów, zwanych dalej sztucznymi sieciami neuronowymi.

Pierwsze sztuczne sieci neuronowe były maszynami analogowymi, co niestety stanowiło jedną z barier ich praktycznych zastosowań, a co za tym idzie, ich rozwoju. Dynamiczny rozkwit modelowania neuronowego zainicjowało, a następnie stymulowało dopiero pojawienie się komputerowych symulatorów sieci neuronowych, zdolnych do rozwiązania stawianego problemu w czasie rzeczywistym (Hertz J. i inni, 1993). Stało się to możliwe dzięki wykładniczej dynamice jaką od lat sześćdziesiątych wykazuje przyrost mocy obliczeniowej obserwowany we współczesnych komputerach.

Krótką historia modelowania neuronowego

W początkowej fazie prowadzone badania naukowe osadzone były głównie w dziedzinie neurofizjologii. Chciano opisać jak najlepiej mechanizmy funkcjonowania ludzkiego mózgu poprzez analizę działania pojedynczych komórek nerwowych. Termin „sztuczne sieci neuronowe” narodził się w 1943 roku po ukazaniu się pracy *McCulloch’a i Pitts’a*. W niej to po raz pierwszy opublikowano matematyczny model neuronu i jego powiązanie z procesem obróbki informacji w oparciu o równoległe oraz rozproszone przetwarzanie danych (Osowski S., 2000).

Sześć lat później *Donald Hebb* odkrył, że informacje mogą być przechowywane między połączeniami poszczególnych neuronów i zaproponował metodę uczenia neuronu, w oparciu o adaptacyjną zmianę wag połączeń między neuronami. Zaowocowało to stworzeniem w 1957 roku przez *Franka Rossenblatt’a* sztucznej sieci neuronowej, tzw. *perceptronu*. Sieć ta, częściowo elektromechaniczna a częściowo elektryczna, wykorzystana była do rozpoznawania znaków. Pomimo wielu wad charakterystycznych dla proponowanej topologii, po opublikowaniu przez autorów wyników prowadzonych badań, nastąpił dynamiczny rozwój tego typu sieci. Na podstawie modelu *Rossenblatt’a* w 1960 roku *Bernad Widrow* zaproponował elementarną sieć typu *Adeline*. Przez połączenie wiele takich elementów powstała topologia *Madaline*. Był to pierwszy neurokomputer wytworzony na potrzeby adaptacyjnego przetwarzania sygnałów, który był oferowany komercyjnie.

W latach 70-tych nastąpiło pewne zahamowanie rozwoju metod sztucznych sieci neuronowych. Stało się to na skutek publikacji wskazującej na ograniczony zakres zastosowań sieci posiadających jedną warstwę (*Minsky, Papert, 1969*). Pomimo krytyki nie zaprzestano tworzenia nowych modeli sieci neuronowych. Dla przykładu wymienić można sieć *Avalanche* zaproponowaną przez *Grossberga* (służyła do rozpoznawania mowy). Inny przykład to *Brain State in the Box Jamesa Andersona* (odpowiednik pamięci asocjacyjnej). W 1982 roku fiński uczony *Tuevo Kohonen* opracował sieci dedykowane do klasyfikacji poprzez wydobycia cech, nie wymagające w procesie uczenia nadzoru nauczyciela.

W latach osiemdziesiątych i dziewięćdziesiątych *Grossberg* i *Carpenter* wprowadzili szereg nowych architektur sztucznych sieci neuronowych oraz rozwinęli teorię adaptacyjnych sieci rezonansowych. Pojawiły się pierwsze sieci ze sprzężeniem zwrotnym. Dużym krokiem w rozwoju dziedziny sztucznych sieci była publikacja *McClellanda*

i Rumelharta wydana w 1986 roku na temat równoległego przetwarzania rozproszonego w topologiach z neuronami radialnymi w warstwie ukrytej. Spowodowało to rozwój sieci wielowarstwowych typu RBF (*Radial Basis Function*), które w przeciwieństwie do tradycyjnych sieci sigmoidalnych, wykorzystują w procesie uczenia techniki optymalizacji lokalnej (Rutkowska D., 1997).

Duży wpływ na rozwój sztucznych sieci neuronowych miał także postęp techniczny w dziedzinie budowy neuroprocesorów stanowiących w istocie analogowe realizacje sprzętowe. Od połowy lat 80-tych zaczął się nieformalny „wyścig” laboratoriów badawczych oraz firm produkujących neuropodobne układy elektroniczne. Osiągnięciami liczącymi się w tym wyścigu są: rosnąca liczba elementów neuropodobnych umieszczonych w zintegrowanej strukturze układu scalonego, duża liczba realizowanych połączeń w topologii sieci oraz znaczna szybkość działania układu. W efekcie wzrosła także ilość praktycznych zastosowań przetwarzania neuronowego, ujawniających się w różnych, często zupełnie odmiennych obszarach życia (Giergiel M. J. i inni, 2002). Można zauważyć, że w istocie w każdej dziedzinie nauki znalazły się jakieś problemy, które udało się rozwiązać albo chociaż lepiej poznać dzięki wykorzystaniu sztucznych sieci neuronowych.

W ostatnich latach sztuczne sieci neuronowe znalazły zastosowanie również w rolnictwie. Ich dobre wyniki w zakresie klasyfikacji oraz predykcji posłużyły do skonstruowania systemów ekspertowych pracujących w czasie rzeczywistym, efektywnie wspierających procesy decyzyjne w wielu gałęziach rolnictwa. Zaowocowało to nawet pojawieniem się pierwszych urządzeń i maszyn rolniczych, których funkcjonowanie opiera się metodach sztucznej inteligencji, a zatem nie wymagających ciągłego nadzoru oraz obsługi. Są to jednak dopiero początki wykorzystania sieci neuronowych w tej dziedzinie. Celem tej pracy jest prezentacja kilku wybranych rozwiązań mających już praktyczne zastosowanie w rolnictwie i wykorzystujących w praktyce techniki przetwarzania neuronowego.

Przykłady aplikacji technik neuronowych w rolnictwie

Jedną z podstawowych właściwości sztucznych sieci neuronowych są ich umiejętności klasyfikacyjne. Zdolność sieci neuronowych do klasyfikacji może być wykorzystana w wielu obszarach rolnictwa. W szczególności może zaowocować w przyszłości inteligentnymi maszynami do zbioru. W oparciu o neuronową technikę rozpoznawania obrazu, maszyna może wykonywać różne prace w rolnictwie bez ingerencji człowieka. Niżej przedstawiono przykłady takich urządzeń, podając ich krótką charakterystykę.

- API (Autonomous Platform and Information system for registration of crops and weeds) - maszyna do wrywania chwastów

Prace prowadzone są w *Danish Institute of Agricultural Sciences* mieszczącym się w Tjele. Robot ten przejeżdżając przez pole skanuje znajdujące się na nim rośliny i zaznacza te, które rozpoznaje jako chwasty. Robot działa automatycznie w oparciu o dane uzyskane z systemu GPS. Następna wersja będzie posiadała możliwość rozpylenia dokładnej, minimalnej ale skutecznej dawki herbicydu. Pozwoli to na zredukowanie zużycia środków chwastobójczych, głównie w trosce o środowisko, o ponad 70%. Projekt ten znany


jest jako **API (Autonomous Platform and Information system for registration of crops and weeds)** czyli autonomiczna platforma i system informacji na potrzeby monitoringu zbiorów i chwastów. Podobne roboty są stosowane już w Stanach Zjednoczonych, jednak tylko do usuwania wszystkich roślin, np. z torów kolejowych.



Rys. 1. Robot do monitoringu zbiorów i chwastów
Fig. 1. Crops and weeds monitoring robot

W skład systemu wchodzi następujące integralne moduły:

- moduł mapujący: realizuje precyzyjne mapowanie pola podczas sadzenia roślin,




Rys. 2. Schemat mapowania pola podczas sadzenia roślin
Fig. 2. Scheme of field mapping during planting

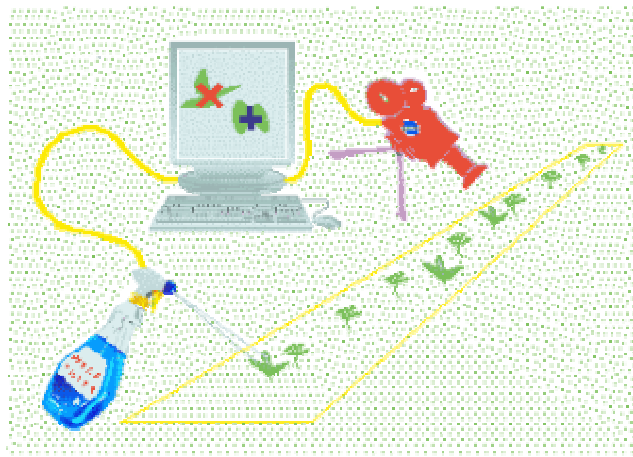
- moduł identyfikujący: realizuje komputerowe rozpoznawanie roślin przy wykorzystaniu sieci neuronowych,
- moduł roboczy: stanowi zintegrowane, zaawansowane narzędzia do usuwania bądź regulacji populacji chwastów.

- ACROSS (Autonomous spatial-temporal Crop and Soil Surveying) - neuronowy robot do monitoringu stanu pola i plonu


Projekt ten ma na celu rozwój koncepcji rolnictwa precyzyjnego w efekcie czego realizowany jest ciągły lub okresowy nadzór nad glebą i plonami. Neurorobot podczas




Rys. 3. Rozpoznawanie kształtu roślin
Fig. 3. Recognizing of plants shape



Rys. 4. Schemat wykrywania i niszczenia chwastów w międzyrzędziach
Fig. 4. Scheme of weeds detecting and destroying in inter-rows spacings



Rys. 5. Neuronowy robot do monitoringu stanu pola i plonu
Fig. 5. Neuronal robot for field and crop state monitoring



Rys. 6. Robot czyszczący wykonany w ramach projektu ISAC
Fig. 6. Cleaning robot made in the confines of ISAC project

przejazdu przez pole monitoruje aktualny stan roślin oraz gleby. Następnie przy pomocy otrzymanych wyników można określić kondycję całego pola jak i plonu. Robot odnotowuje każde pojawienie się choroby, insektów bądź zagrożenie innego typu.

- ISAC (Intelligent Sensor for Autonomous Cleaning in livestock buildings) - neurorobot czyszczący

Celem ISAC jest rozwinięcie koncepcji inteligentnego systemu sensorów połączonych z autonomicznym systemem czyszczącym, mający zastosowanie w budynkach inwentarskich. Wspomoże to niewątpliwie środowisko pracy, zapewni standard higieny i zoptymalizuje zużycie środków czyszczących w gospodarstwach produkcji zwierzęcej.

- SLUGBOT - neurorobot do wykrywania oraz usuwania ślimaków

Na University of West England's w Intelligent Autonomous Systems Laboratory stworzono robota wykorzystującego sieć neuronową zdolną do rozpoznawania echa. Robot osadzony na samojezdnym podwoziu kołowym, posiada ruchome ramię długości półtora metra umieszczone na ob-

rotnicy, które wykorzystuje się jako skaner, a także chwytacz szkodników.

Urządzeniem wykrywającym jest sonar ultradźwiękowy, oraz emiter podczerwieni. Robot wspomagany jest także przez GPS oraz DGPS. Proces rozpoznawania odbywa się etapowo. Robot porusza się odcinkami adekwatnymi do długości największej średnicy ramienia. Skaner obraca się wokół korpusu trzy razy. Końcowa klasyfikacja szkodników odbywa się poprzez analizę odbitych fal ultradźwiękowych. Sieć uczy się rozpoznawać i rozróżniać echo poszczególnych obiektów. Echo odbijane przez organizmy żywe jest o wiele słabsze niż to zwracane przez ciała stałe (kamień).

Slugbot jest neurorobotem zdolnym bez pomocy człowieka do wykonania skanowania wybranego fragmentu pola pszenicy w poszukiwaniu ślimaków. Robot ten wyposażony jest w ramię obrotowe o zasięgu 1,5m i potrafi rozpoznawać i odróżniać ślimaki od innych obiektów, np. kamieni. Jest w stanie pracować w różnych warunkach oświetleniowych. Dzięki zastosowaniu mikrobiologicznych ogniw paliwowych, robot ten może samodzielnie operować bez pomocy człowieka w czasie największej aktywności ślimaków i ładować baterie podczas odpoczynku. Zebrane ślimaki są wykorzystywane jako paliwo do zasilania ogniw paliwowych.



Rys. 7. Slugbot – neurorobot do wykrywania ślimaków
Fig. 7. Slugbot – neurorobot for slugs detecting

- TARZAN – robot drzewny



Rys. 8. Tarzan – robot drzewny
Fig. 8. Tarzan – robot for trees monitoring

Robot drzewny wspomaga proces inteligentnego monitorowania zmian środowiskowych w koronach drzew. Wyposażony jest w kombinację czujników, kamerę a także łącze bezprzewodowe. Przemieszcza się po specjalnym kablu umożliwiającym pobieranie danych. Całość konstrukcji oparta jest na zasilaniu słonecznym. Projekt opiera się na procesie zbierania informacji o środowisku leśnym, takich jak wpływ zmian w nasłonecznieniu, poziom dwutlenku węgla oraz wilgotności. Głównym motywem badań jest chęć przewidywania zmian w środowisku naturalnym spowodowanym działalnością człowieka. Naukowcy chcą w ten sposób zapobiec postępującej biodegradacji lasów.


- CRoPS (Crop Rotation Planing System) - system sterujący płodozmiianem

System komputerowy sterujący płodozmiianem poszczególnych pól lub całego gospodarstwa. Ma na celu analizę planowania siewu pod względem wymagań produkcji, zapotrzebowania na wytworzony produkt oraz możliwości finansowe rolnika. System planowania oparty jest na sztucznych sieciach neuronowych uwzględnia między innymi:

- typ gleby poszczególnych pól w gospodarstwie,
- potencjał erozyjny gleby,
- terminy wysiewu nawozów dostosowane do poszczególnych roślin i czynników klimatycznych,
- terminy oprysków i okres karencji.

Plany są podawane dla indywidualnych pól co zapewnia kompatybilność rotacji poszczególnych roślin w gospodarstwie tak aby spotkało się to z preferencjami rolnika co do produkcji.

- Elektroniczny nos



Rys. 9. Etapy pracy elektronicznego nosa
Fig. 9. Working stages of electronic nose


The Pacific Northwest National Laboratory prowadzi badania nad ochroną środowiska i zarządzaniem odpadami. Obejmują one również systemy czasu rzeczywistego rozpoznawania zanieczyszczeń oraz chwastów na polach. Sieci neuronowe sprzężone są w tym rozwiązaniu z czujnikami chemicznymi oraz spektrometrami. System przygotowany

jest do automatycznego rozpoznawania zanieczyszczeń oraz chwastów. Pracując w systemie zintegrowanym z narzędziami ochrony roślin dokonuje w sposób automatyczny adekwatnego oprysku roślin.

Program wykorzystuje również sieć neuronową do rozpoznania uprawy, a następnie poprzez wizualizację binarną, przesyła odpowiednie sygnały do dysz opryskiwacza.

- Neuronowy klasyfikator plonów

Zdjęcia wykonywane przez satelity i konwencjonalne samoloty, wykorzystywane są do uzyskiwania wielu pomocnych w rolnictwie informacji. *The British Machine Vision Association and Society for Pattern Recognition* opracowało, na podstawie technik rozpoznawania obrazów aplikację umożliwiającą klasyfikację plonów. Sieć neuronowa na podstawie struktury zasiewów, nawiązującą do cech zbóż, takich jak wilgotność liści, rozmieszczenie roślin, ulistnienie, przewiduje plon w danej jednostce czasowej. System pozwala na 75% skuteczność rozpoznawania w przypadku rozpoznawania 5 różnych plonów.



Rys. 10. Mapa plonów
Fig. 10. The map of yields

Uwagi końcowe

Warto uświadomić sobie, że neurokomputery są istotnie różne od tradycyjnych maszyn cyfrowych. Ze względu na biologiczną inspirację ich powstania, pod względem sposobu w jaki przetwarzają informację bardziej przypominają organizmy żywe. Nie realizują założonych z góry algorytmów, ale posługują się „wiedzą” oraz „doświadczeniem” zdobytym podczas procesu uczenia. Są omylne i często

niedokładne, ale posiadają intuicję oraz zdolność przewidywania, podobną do tej, jaką posiadają organizmy żywe. Nie tyle rozwiązują postawione przed nimi problemy, co właściwie je modelują, odpowiednio dostrajając wagi synaptyczne swoich neuronów podczas procesu uczenia. Potrafią również dostrzegać niezauważalne na pozór związki i korelacje zawarte w danych, którymi się je zasili.

Sztuczne sieci neuronowe w przeciwieństwie do konwencjonalnych technik przetwarzania danych są słabymi maszynami matematycznymi i raczej nie nadają się do typowego przetwarzania opartego o algorytmy. Bardzo dobrze natomiast nadają się do zadań związanych z rozpoznawaniem obrazów (nawet tych o niepełnej bądź zaszumionej informacji) oraz do wszelkiego rodzaju zadań optymalizacyjno-decyzyjnych.

Obecnie nawet w prasie codziennej pojawiają się artykuły opisujące fascynujące zjawisko jakim są sztuczne sieci neuronowe. Można chyba zaryzykować twierdzenie, że stały się one po prostu modne. Zjawisku temu towarzyszy pojawienie się licznych, przyjaznych użytkownikowi narzędzi, w postaci wyrafinowanych pakietów programowych, symulujących różne topologie sieci neuronowych.

Przedstawione wyżej przykłady praktycznego wykorzystania technik neuronowych w rolnictwie stanowią jedynie mały fragment potencjalnych zastosowań, jakie reprezentuje szeroko rozumiane modelowanie neuronowe.

Literatura

- [1] Krawiec K., Stefański J. (2004). *Uczenie maszynowe i sieci neuronowe*: Wydawnictwo Politechniki Poznańskiej, Poznań
- [2] Giergiel M. J., Hendzel Z., Żylski W. (2002). *Modelowanie i sterowanie mobilnych robotów kołowych*: PWN, Warszawa
- [3] Biało M. (2000). *Podstawowe właściwości sieci neuronowych i hybrydowych systemów ekspertowych*: Wydawnictwo Uczelniane Politechniki Koszalińskiej, Koszalin
- [4] Rutkowska D. (1997). *Inteligentne systemy obliczeniowe-algorytmy genetyczne i sieci neuronowe w systemach rozmytych*: Akademicka Oficyna Wydawnicza PLJ, Warszawa
- [5] Rutkowska D., Piliński M., Rutkowski L. (1997). *Sieci neuronowe, algorytmy genetyczne i systemy rozmyte*: Wydawnictwo Naukowe PWN, Warszawa-Łódź
- [6] Osowski S. (2000). *Sieci neuronowe do przetwarzania informacji*: Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa
- [7] Hertz J., Krogh A., Palmer R. G. (1993). *Wstęp do teorii obliczeń neuronowych*: WNT Warszawa.