

MICHAŁ ZASADA

Możliwość wykorzystania sztucznych sieci neuronowych w nauce i praktyce leśnej

Potentials for using artificial neuron networks
in forest science and practice

Abstract. The report presents basic information on artificial neuron networks and an example of their practical use to defining stand volume increment as basing on age and upper height. The results obtained from a trained neuron network were compared to those from volume increment tables.

Keywords: artificial neuron networks, artificial intelligence, volume increment, approximation of functions.

Wstęp

Wraz z rozwojem nauki pojawiają się nowe, ciekawe metody badawcze. W ostatnich latach szczególnie rozwinęły się metody oparte na badaniach nad sztuczną inteligencją, w tym przede wszystkim sieci neuronowe.

Zagadnienie sztucznych sieci neuronowych nie jest nowe, gdyż początki badań nad sztuczną inteligencją datują się już na lata czterdzieste naszego stulecia. Po kryzysie, jaki dotknął tę dziedzinę wiedzy w latach siedemdziesiątych, obecnie przeżywa ona gwałtowny rozwój. Stało się to możliwe dzięki szybkiemu rozwojowi elektroniki i techniki komputerowej oraz przeznaczaniu na badania nad tym tematem ogromnych środków.

Nie ma chyba dziś dziedziny wiedzy, w której sztuczne sieci neuronowe nie znalazły (lub nie mogłyby znaleźć) zastosowania. Stały się one, jeśli można użyć takiego sformułowania, po prostu modne. Współcześnie próbuje się je zastosować praktycznie we wszystkich dziedzinach wiedzy: w fizyce, biologii, medycynie, ekonomii, psychologii, naukach społecznych i wielu innych. Przykładów ich zastosowań są tysiące, nie sposób więc ich nawet wymienić. Opisywane są one szeroko m.in. w podręcznikach z tego zakresu (np. Tadeusiewicz 1993, 1998, Osowski 1994, 1996). Możliwość zastosowania metod sztucznej inteligencji w nauce i praktyce została dostrzeżona również przez leśników (Brack, Marshall 1992).


O popularności technik badawczych wykorzystujących sztuczną inteligencję świadczy wiele faktów:

- pojawia się coraz więcej oprogramowania dającego możliwość łatwego ich wykorzystania, np. elementy zawarte w dużych, popularnych pakietach statystycznych lub matematycznych (Statistica, SPSS, SAS, Matlab), czy też duże, wyspecjalizowane pakiety oprogramowania, jak Stuttgart Neural Network Simulator (SNNS) (Zell 1995) oraz Neuronix firmy AITech (Michalik 1999),
- na wielu wyższych uczelniach prowadzone są wykłady i badania z zakresu sieci neuronowych; w Polsce największymi ośrodkami zajmującymi się badaniami w tej dziedzinie są Akademia Górniczo-Hutnicza w Krakowie, Politechnika Warszawska, Uniwersytet Mikołaja Kopernika w Toruniu, Politechnika Częstochowska, Politechnika Zielonogórska, Politechnika Koszalińska i Instytut Biocybernetyki i Inżynierii Biomedycznej PAN w Warszawie,
- istnieją czasopisma naukowe poświęcone tylko sieciom neuronowym (np. Neural Networks, Neurocomputing).

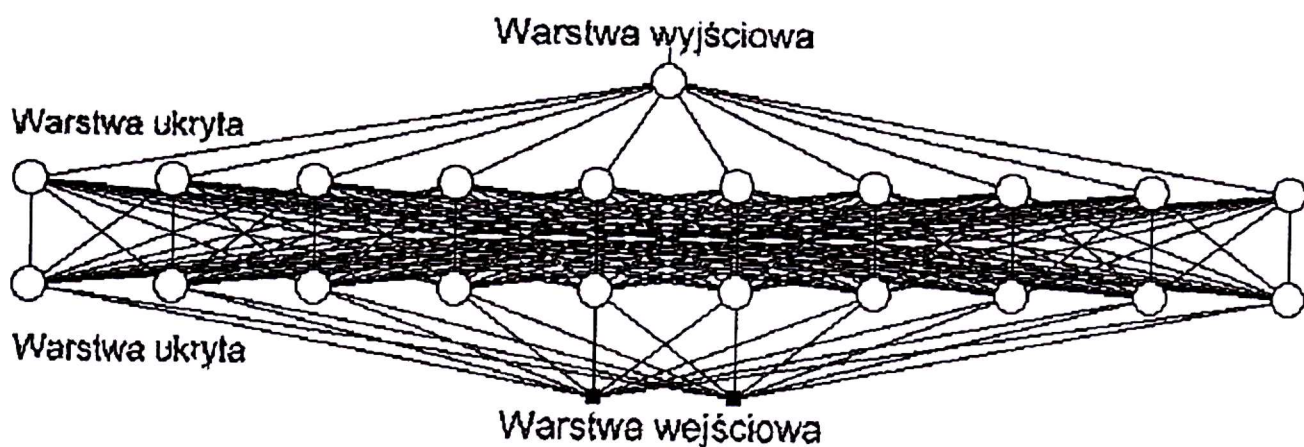
Celem niniejszej pracy jest przedstawienie podstawowych informacji na temat budowy i działania sztucznych sieci neuronowych oraz możliwości ich zastosowania w nauce i praktyce leśnej. Jako przykład obrazujący możliwości sieci przedstawiono propozycję określania za pomocą sztucznej sieci neuronowej przyrostu miąższości drzewostanu na podstawie wieku i wysokości górnej.

Budowa i funkcjonowanie sztucznych sieci neuronowych

Budowa sztucznych sieci neuronowych wzorowana jest na budowie mózgu składającego się z wielu komórek nerwowych – neuronów. Powszechnie stosowany model sztucznego neuronu po raz pierwszy został przedstawiony przez McCullocha i Pittsa w 1943 (ryc. 1). Sygnały wejściowe (X_1, X_2, X_3) mnożone są przez wagi poszczególnych wejść (W_1, W_2, W_3), a następnie sumowane i przetwarzane przez funkcję aktywacji. Wynik tych operacji



RYC. 1. Schemat sztucznego neuronu.



RYC. 2. Schemat przykładowej sztucznej sieci neuronowej

jest sygnałem wyjściowym neuronu (Y). Schemat taki jest łatwy do zaimplementowania np. w postaci programu w dowolnym języku programowania.

Neurony tutaj opisane łączy się w sieci. Wyjścia neuronów tworzących warstwę, łączy się z wejściami innych, również tworzących warstwę. Najczęściej buduje się sieci dwu- lub trzywarstwowe. Złożone są one z warstwy wejściowej (która nie przetwarza informacji, a jedynie przekazuje ją do kolejnej warstwy), jednej lub dwóch warstw ukrytych oraz warstwy wyjściowej (ryc. 2). Taka architektura sieci wystarcza do rozwiązania większości postawionych przed nią problemów.

Wykorzystanie sztucznych sieci neuronowych odbywa się według określonego schematu. Po zaprojektowaniu i zbudowaniu sieci przystępuje się do jej uczenia. W zależności od tego, jaki problem chcemy rozwiązać za pomocą sieci, stosować można trening nadzorowany bądź nienadzorowany. Najlepiej udokumentowane i najczęściej stosowane w praktyce jest uczenie nadzorowane. Polega ono na tym, że do sieci dostarczamy zestaw danych wejściowych oraz oczekiwaną przez nas wartość wyjściową. Zadaniem sieci jest takie dobranie wag poszczególnych połączeń między neuronami, by błąd uzyskiwany na wyjściu sieci był jak najmniejszy (Tadeusiewicz 1993).

Właściwości sieci neuronowych

W sztucznych sieciach neuronowych zamiast programowania stosowany jest mechanizm uczenia. W praktyce oznacza to, że mogą być one zastosowane wszędzie tam, gdzie nie znamy związku pomiędzy oddziaływaniem jakichś czynników na wynik. Nie musimy dostarczać sieci sposobu rozwiązania problemu, a jedynie odpowiednio dużą ilość wzorców – wyników obserwacji – które pozwolą jej na odwzorowanie rzeczywistości bez znajomości zasad nią rządzących. Jest to jednocześnie duże niebezpieczeństwo dla stosujących sieci. Prowadzić może do wysnucia wniosku, że badania, których celem jest poznanie przyczyn zjawisk, są niepotrzebne, skoro sieć można zastosować bez tej wiedzy.

Jedną z podstawowych cech sztucznych sieci neuronowych jest zdolność do uogólniania (generalizacji). Polega ona na tym, że sieć potrafi dawać sensowne wyniki nawet dla danych wejściowych, z którymi się wcześniej nie zetknęła. Oznacza to, że sieci mogą być z


powodzeniem zastosowane do prognozowania zjawisk. Sieci neuronowe charakteryzują się ponadto dużą elastycznością i nieliniowością, stąd mogą służyć do aproksymacji bardzo skomplikowanych funkcji. Jakość tej aproksymacji jest porównywalna z najlepszymi statystycznymi metodami regresji nieliniowej.

Przetwarzanie informacji w sieci przebiega jednocześnie we wszystkich neuronach, jest to więc typowe równoległe przetwarzanie informacji. Jest ono dużo wydajniejsze i szybsze, niż w klasycznym, szeregowym przetwarzaniu danych przez klasycznie napisane programy komputerowe. Szybkość sieci pozwala stosować je w systemach czasu rzeczywistego, np. w systemach sterowania (Tadeusiewicz 1998, Osowski 1996).

Przykład zastosowania sieci

Aby pokazać potencjalne możliwości wykorzystania sztucznych sieci neuronowych w praktyce, przedstawiono przykład ich zastosowania do szacowania przyrostu miąższości drzewostanu. Danymi, które posłużyły do określania przyrostu, był wiek drzewostanu i jego wysokość górna. Jest to zagadnienie, które z powodzeniem może być rozwiązane innymi metodami, np. modelami wzrostu czy wzorami empirycznymi (Zasada 1998, Dudek 1994), stanowić jednak może również przykład wykorzystania sieci.

Ponieważ dokładne określanie przyrostu miąższości w drzewostanie jest trudne, a przy tym nie dysponowano odpowiednimi danymi pomiarowymi, do trenowania i weryfikacji sieci użyto danych pochodzących z bazy danych modelu granicznego dla jodły (Zasada 1998). Oczywiście w praktyce mogą być one zastąpione danymi pochodzącymi z pomiaru lub szacunku. Aby pokazać przestrzeń, która będzie musiała być odwzorowana przez sieć



RYC. 3. Zależność bieżącego rocznego przyrostu miąższości od wieku i wysokości górnej drzewostanu (dane z modelu wzrostu dla jodły opracowane programem Surfer)

[G:\NEURAL\SPHINX\PRZYROST.LRN]								
	30							
	A	B	C	D	E	F	G	H
Wiek	Wzrost	Wzrost	Wzrost					
Wzrost	Wzrost	Z	Z					
30	30	8,9	17,4					
30	30	7,8	12,4					
35	35	8,9	15,3					
35	35	10,3	9,7					
35	35	11,6	12,5					
40	40	9,3	15,2					
40	40	14,4	13,8					
40	40	11	8,8					
40	40	12,7	10,9					
45	45	13	9,3					
45	45	17	15,2					
45	45	15	12					
45	45	11	7,1					

Dane zbiorcze

RYC. 4. Fragment arkusza danych modułu Neuronix

charakter zależności bieżącego rocznego przyrostu miąższości od wieku i wysokości górnej dla jodły przedstawiono na wykresie (ryc. 3). Sieć do obróbki danych zbudowano przy użyciu programu Neuronix, będącego elementem pakietu sztucznej inteligencji Sphinx firmy AITech (Michalik 1999). Fragment arkusza z danymi przedstawiono na rysunku (ryc. 4).

Do rozwiązania przykładu zbudowano kilka sieci o różnej strukturze, z których po przeprowadzeniu testów uczenia wybrano najlepszą. Była to sieć jednokierunkowa składająca się z warstwy wejściowej z dwóch neuronów, dwóch warstw ukrytych złożonych z 10 neuronów każda oraz warstwy wyjściowej w postaci jednego neuronu. Posiadała ona pełne połączenia między warstwami, co oznacza, że każdy neuron w danej warstwie był połączony ze wszystkimi neuronami warstwy następnej (ryc. 3). Sieć tę trenowano według schematu uczenia nadzorowanego metodą wstecznej propagacji błędów. W neuronach sieci zastosowano najczęściej wykorzystywaną sigmoidalną (logistyczną) funkcję aktywacji. Ponieważ funkcja ta przyjmuje wartości od 0 do 1, przed rozpoczęciem treningu konieczne było przetworzenie (standaryzacja) wektorów danych wejściowych i wyjściowych (Michalik 1999). Warunkiem zakończenia nauki było osiągnięcie przez sieć błędu mniejszego od założonego (0,01). Łącznie zostało zaprezentowanych 169 wzorców sieci, obejmujących dane dla wieku od 30 do 200 lat i dla bonitacji wzrostowej (mierzonej wysokością górną drzewostanu w wieku 100 lat) od 18 do 34 m.

Wyniki

Po zakończeniu trenowania sieci sprawdzono, w jaki sposób odwzorowuje ona zależność bieżącego rocznego przyrostu miąższości od wieku i wysokości górnej drzewostanu. W tym celu spośród 169 danych wybrano 36 tak, by reprezentowały one cały zakres wieku i bonitacji. Wiek i wysokość górna drzewostanu posłużyła jako dane wejściowe dla wyuczonej sieci. Uzyskane wyniki porównano z wartościami rzeczywistymi, obliczając błąd procentowy wtórny określania przyrostu miąższości drzewostanu za pomocą sieci.

Błąd procentowy wtórny wahał się od -14,7 do +3,9% i wyniósł średnio -1,1% z odchyleniem standardowym 4,05%. Ponad 80% testowanych wyników charakteryzowało się błędami w zakresie od -2,3 do +4,6%. Uzyskane błędy nie są duże, co potwierdza możliwość zastosowania sieci w praktyce. Największe błędy, przekraczające 10%, uzyskano dla wieku poniżej 50 lat w drzewostanach o wysokiej bonitacji.

Podsumowanie i wnioski

W pracy podjęto próbę pokazania możliwości zastosowania sztucznych sieci neuronowych do rozwiązywania problemów z zakresu dendrometrii. Uzyskane za pomocą wytrenowanej sieci przyrosty miąższości są bliskie wartościom rzeczywistym. Dla porównania błąd standardowy tablic przyrostu miąższości dla sosny (Dudek 1994) dla przyrostu pięcioletniego określanego na podstawie wieku i bonitacji wzrostowej wynosi 16,9%. Empiryczna dokładność tych tablic dla wariantu uwzględniającego bonitację i wiek dała średnią arytmetyczną błędów 12,1% i odchylenie standardowe 16,1% (Dudek 1994). Na tym tle sieć neuronowa nie wypada wcale gorzej.

Istotną wadą sztucznych sieci neuronowych jest jednak to, że nie dają one praktycznie żadnej informacji o przyczynach zjawisk ani na temat zależności między różnymi cechami czy czynnikami. Stąd ich zastosowanie nie może w żaden sposób zastąpić rzetelnych badań empirycznych.

*Zakład Dendrometrii i Nauki o Produkcyjności Lasu
SGGW, ul. Rakowiecka 26/30, 02-528 Warszawa
zasada@delta.sggw.waw.pl*

Literatura

1. **Brack C. L., Marshall P.**, 1992: Using artificial intelligence to integrate forest management information. Proceedings from IUFRO Conference Integrating Forest Information over Space and Time. January 1992, Wood and Turner (eds), ANUTECH Pty Ltd, Canberra, Australia. pp 207-218.
2. **Dudek A.**, 1994: Tablice przyrostu miąższości dla sosny. Wyd. SGGW Warszawa.
3. **Michalik K.**, 1999: Neuronix 2.3 dla Windows 9x/NT. Symulator sztucznych sieci neuronowych. Podręcznik użytkownika. AITech, Katowice.
4. **Osowski S.**, 1994: Sieci neuronowe. OWPW, Warszawa.

5. **Osowski S.**, 1996: Sieci neuronowe w ujęciu algorytmicznym. WNT Warszawa.
6. **Tadeusiewicz R.**, 1993: Sieci neuronowe. Akademicka Oficyna Wydawnicza, Warszawa.
7. **Tadeusiewicz R.**, 1998: Elementarne wprowadzenie do techniki sieci neuronowych z przykładowymi programami.
8. **Zasada M.**, 1998: Model wzrostu dla jodły pospolitej (*Abies alba* Mill.). Praca doktorska. Maszynopis w Katedrze Produkcyjności Lasu SGGW, Warszawa.
9. **Zell A. i in.**, 1995: Stuttgart Neural Network Simulator. SNNS v.4.0. Institute for Parallel and Distributed High Performance Systems, University of Stuttgart.

Summary

Potentials for using artificial neuron networks in forest science and practice

New interesting research methods develop parallel to the development of science. Methods based on studies on artificial intelligence have especially been developed in the recent years, including first of all neuron networks.

This report aimed to presenting basic information on structure and function of artificial neuron networks, and potentials of their use in forest science and practice. A proposal of defining stand volume increment on the basis of age and upper height, using artificial neuron network, was presented as an example showing potentials of the network. The data was generated with the aid of a growth model for fir (Zasada 1998). In the practice they can be substituted with data derived from measurement or estimation.

One-direction network as presented on Fig.1 was used for solving the case, simulated by the Neuronix program (Michalik 1999). It was trained according to the learning scheme controlled with the method of backward propagation of errors. The sigmoidal (logistic) function of activation was used most often in the network neurons.

After finishing the network training there was a checking made, how does it show the relationship between the current annual volume increment and the age and the upper height of stand. For 36 data pairs (age – upper height) the secondary percentage error was defined in estimation of stand volume increment using the network. It amounted from – 14.7 to +3.9% and was –1.1% on the average, with 4.05% of standard deviation. Over 80%-tested results had errors from the range from – 2.3 to 4.6%. The errors obtained are not very great, this confirming a potential for using the network in practice. Just for comparison, studying the precision of the Dudeks tables for estimating volume increment in pine, in the variant taking stand quality and age into account, gave the arithmetic mean of errors equal to 12.1% and standard deviation 16.1% (Dudek 1994). The neuron network does, by no means, present itself worse on this background.

There is however one fault in networks – they do neither practically give any information on causes of events, nor on relationships between various features or factors. Hence their use can by no means substitute reliable empirical studies.