

GNIEWKO NIEDBAŁA¹, ROBERT KORZENIEWICZ²

¹Inżynierii Biosystemów
Uniwersytet Przyrodniczy w Poznaniu

²Katedra Hodowli Lasu
Uniwersytet Przyrodniczy w Poznaniu

WYZNACZANIE ISTOTNOŚCI CECH BIOMETRYCZNYCH DO PREDYKCJI PRZEŻYWAŁNOŚCI SOSNY ZWYCZAJNEJ (*PINUS SYLVESTRIS* L.) Z UŻYCIEM METOD MODELOWANIA NEURONOWEGO

DETERMINING THE SIGNIFICANCE OF BIOMETRIC FEATURES
FOR PREDICTING THE SURVIVABILITY OF PINE (*PINUS SYLVESTRIS* L.)
WITH THE USE OF NEURAL MODELLING METHODS

Abstrakt

Wstęp. Sosna zwyczajna odgrywa w Polsce szczególną rolę zarówno pod względem przyrodniczym, jak i gospodarczym. Próba wyznaczenia za pomocą sieci neuronowych najistotniejszej cechy biometrycznej umożliwiającej predykcję przeżywalności, może mieć wysokie walory użytkowe. Dlatego też celem pracy było zbudowanie predykcyjnego modelu neuronowego, mającego wyznaczyć najistotniejsze cechy biometryczne drzew (sosny zwyczajnej) rosnących w czterdziestoletnim drzewostanie, które decydują o przeżyciu i zajmowanej pozycji biosocjalnej.

Materiał i metody. Do realizacji celu pracy poddano analizie zebrane dane empiryczne z pierwszych dziesięciu lat oraz z trzydziestego i czterdziestego roku życia drzew w niepielęgowanym drzewostanie. Materiał badawczy pochodzi ze stałej powierzchni badawczej zlokalizowanej na terenie Nadleśnictwa Doświadczalnego Siemianice (Leśny Zakład Doświadczalny Uniwersytetu Przyrodniczego w Poznaniu). Do budowy modelu użyto zmiennych niezależnych – średnicy i wysokości drzew (w każdym roku).

Wyniki. Wygenerowano dwa modele neuronowe. Pierwszy model dla analiz przeżywalności w 30 roku (M30) oraz drugi model dla analiz przeżywalności w 40 roku (M40). Struktura modelu M30 i M40 przyjęła postać 18:18-36-36-1. Wygenerowane modele zostały oparte na wielowarstwowej sieci neuronowej MLP z dwoma ukrytymi warstwami.

Wnioski. W przeprowadzonym wnioskowaniu za pomocą wygenerowanego modelu neuronowego z użyciem analizy wrażliwości sieci wskazało najważniejsze cechy biometryczne w predykcji przeżywalności drzew sosny zwyczajnej. Są to średnica w czwartym (d4 – ranga 1) i piątym (d5 – ranga 2) roku życia drzewa.

Słowa kluczowe: predykcja, model neuronowy, sosna zwyczajna, konkurencja wewnątrzgatunkowa, przeżywalność

Wstęp

W nowoczesnym modelu leśnictwa preferowane są takie sposoby zagospodarowania lasu, które stymulują naturalne procesy odnawiania drzew przez tworzenie optymalnych warunków środowiskowych. Powstawanie i rozwój odnowień naturalnych są bardzo ważnymi elementami stabilności ekosystemów leśnych. Przyjmuje się, że lasy naturalne dają możliwość obiektywnej oceny różnych strategii życiowych drzew i warunków środowiskowych sprzyjających powstaniu i rozwojowi odnowień (Drozdowski, 2013). Drzewostan ze względu na długowieczność drzew podlega dwojakiego rodzaju zmienności: cyklicznej, dotyczącej przede wszystkim procesów wzrostowych oraz ciągłej, następującej w bardzo długim czasie życia drzewostanu i dotyczącej przede wszystkim procesów rozwojowych (Szymański, 1996). Jednym z ważniejszych procesów zachodzących w drzewostanie jest proces naturalnego przemieszczania się drzew w jego warstwach (Ceitel, 1994). Skutkiem tego zjawiska jest wydzielenie się drzew (zamieranie) i swoista struktura drzewostanu. Intensywność i rytm procesu naturalnego ubytku drzew z drzewostanu zależy od wielu czynników (Jaworski, 2004). Do ważniejszych z nich należą: cechy gatunkowe (w szczególności rytm i tempo wzrostu), zagęszczenie drzew oraz zjawisko konkurencji. Sterowanie kształtowaniem się struktury drzewostanu należy do ważniejszych zadań hodowli lasu związanych z prowadzeniem cięć pielęgnacyjnych. Wskazanie we wczesnej fazie rozwojowej cechy decydującej o przyszłości wybranego drzewa może być pomocną wskazówką, która może ułatwić prowadzenie pielęgnacji drzewostanów (Szymański, 1964). Próby wykorzystania sztucznych sieci neuronowych do wskazania istotnych cech, decydujących o przeżyciu podejmowano w odniesieniu do brzozy brodawkowatej (Niedbała i in., 2010).

Sztuczne sieci neuronowe (SSN) należą do technik modelowania, które mają największe zastosowanie w tworzeniu nieliniowych modeli zjawisk i procesów. Charakteryzują się bowiem zdolnością do odwzorowywania bardzo złożonych funkcji. Powszechnie stosowane modele liniowe do opisu zjawisk i procesów w różnych dziedzinach i dyscyplinach naukowych często opierają się na aproksymacji liniowej. Metoda ta prowadzi do formułowania niesłusznych opinii i wniosków o całkowitym braku możliwości opisu matematycznego analizowanych systemów. W takich przypadkach zastosowanie metod modelowania neuronowego może doprowadzić do najszybszego i najwygodniejszego rozwiązania problemu. Sieci neuronowe mogą być stosowane wszędzie tam, gdzie pojawiają się problemy związane z tworzeniem modeli matematycznych pozwalających automatycznie odwzorować złożone zależności pomiędzy sygnałami wejściowymi a sygnałami wyjściowymi (Duch i in., 2000).

Sztuczne sieci neuronowe mają zastosowanie w wielu dziedzinach: ekonomii i finansach, medycynie, rolnictwie, elektronice itd. Zagadnienia, do których wykorzystuje się ten instrument, to m.in.: aproksymacja, prognozowanie, przewidywanie danych wyjściowych na podstawie danych wejściowych bez konieczności jawnego definiowania związku pomiędzy nimi, klasyfikacji i rozpoznawanie, kojarzenie danych w proce-

sach wnioskowania i wykrywania powiązania pomiędzy danymi, analizy danych w aspekcie poszukiwania związków pomiędzy danymi (Grahovac i in., 2016; Koszela i in., 2016; Mishra i in., 2016; Niedbała i in., 2016; Wojciechowski i in., 2016).

Ze względu na szczególną przyrodniczą i gospodarczą rolę sosny zwyczajnej próba wyznaczenia za pomocą sztucznych sieci neuronowych najistotniejszej cechy biometrycznej umożliwiającej predykcję przeżywalności, może mieć wysokie walory użytkowe.

Material i metody

Pomiary i obserwacje pochodzą z części powierzchni doświadczalnej Katedry Hodowli Lasu z sosną zwyczajną (*Pinus sylvestris* L.), założoną na terenie Leśnego Zakładu Doświadczalnego Siemianice w oddziale 25 h, a jego położenie geograficzne to 51°12'N i 18°03'E. Typ siedliskowy lasu to bór mieszany świeży (BMśw), wykształcony na glebie bielcowo-rdzawej, porolnej, wytworzonej z polodowcowych piasków luźnych (Szymański, 1982). Pod względem regionalizacji przyrodniczo-leśnej (Kliczkowska i Zieleny, 2012) jest to Kraina Śląska (V), Mezonegion Równiny Oleśnickiej (V.18).

Doświadczenie zostało założone w 1970 roku, w regularnej więźbie (1 m × 1 m), z wykorzystaniem jednorocznych sadzonek sosny. Zagęszczenie początkowe wyniosło 10 tys. szt./ha (tab. 1). Na powierzchni nie prowadzono cięć pielęgnacyjnych. (Szymański, 1982), jednak na skutek naturalnych procesów będących wynikiem ostrej konkurencji wewnątrzgatunkowej do wieku 40 lat przeżyło 26,2% osobników. Do wykonania analizy wykorzystano dane archiwalne Katedry Hodowli Lasu pochodzące z pomiarów z pierwszego dziesięciolecia istnienia doświadczenia oraz przeprowadzonych w 30 i 40 roku życia drzew (tab. 2). Układ eksperymentu i sposób prowadzenia pomiarów umożliwił identyfikację każdego drzewa i przypisanie mu wyniku obserwacji zrealizowanej w kolejnych latach (Korzeniewicz, 2006).

Tabela 1. Zagęszczenie i śmiertelność sosny w doświadczeniu w różnych okresach

Wiek biologiczny drzew	Zagęszczenie	Śmiertelność (%)
0	10 000	–
10	9 830	1,7
30	3 230	67,7
40	2 620	73,8

Budowa modelu neuronowego opiera się na określeniu danych wejściowych (zmiennych niezależnych) i danych wyjściowych (zmiennych zależnych). W niniejszej analizie na wejściu sieci zaprezentowano właściwości biometryczne sosny, którymi są dwie podstawowe cechy charakteryzujące tempo wzrostu w pierwszych dziesięciu latach życia drzewa. Były to wysokość (h) oraz średnica drzewa (d_0 – średnica sosny zmierzona na wysokości szyi korzeniowej) z pierwszych dziesięciu lat. Ponieważ pomiary

Tabela 2. Zestawienie wybranych cech biometrycznych pochodzących z różnych okresów badań prowadzonych w doświadczeniu

Wiek biologiczny drzew	DBH (cm) – pierśnica	h (m) – wysokość
10*	5,06	2,69
30	10,8	13,76
40	14,26	18,20

* d_0 – średnica zmierzona na wysokości szyi korzeniowej.

rozpoczęto od drugiego roku życia, całkowita liczba cech wynosi 18 (9 lat po 2 cechy). Zbiór danych wejściowych tworzył macierz 970 przypadków. Na wyjściu sieci zaprezentowano tylko jedną cechę zależną – przeżywalność, w postaci lingwistycznej TAK lub NIE (TAK – drzewo przeżyło, NIE – drzewo obumarło) w 30 i 40 roku badań. Do budowy modeli neuronowych analizujących przeżywalność w 30 i 40 roku życia drzewa użyto Automatycznego Projektanta Sieci (APS) z pakietu Statistica.

Założeniem dla APS był niestandardowy podział danych w stosunku 70:15:15 (%). Liczba analizowanych przypadków wyniosła 928. Zbiór uczący wyniósł 650 przypadków, walidacyjny i testowy po 139 przypadków. Ponadto po wstępnych testach wybrano do dalszych analiz sieć typu perceptron wielowarstwowy MLP z dwoma warstwami ukrytymi oraz maksymalnie 36 neuronami w każdej ukrytych warstwie.

Przy projektowaniu modelu neuronowego, szczególnie nacisk został położony na minimalizację błędu dla zbioru walidacyjnego. W kolejnym etapie, po wytworzeniu modelu, wykonuje się analizę wrażliwości sieci, która wskazuje największy wpływ cech niezależnych – wysokości oraz średnicy drzewa na cechę zależną w postaci przeżywalności drzewa. Ponadto wykreśla się krzywą ROC oraz generowane są wykresy – tzw. powierzchnie odpowiedzi sieci dla dwóch cech o największym ilorazie przyrostu błędu. Wskaźnik ten definiuje stosunek błędu do błędu otrzymanego przy użyciu wszystkich cech niezależnych. Im jest on większy, tym większa jest istotność danej cechy. W przypadku gdy przyjmie on wartość poniżej 1, zaleca się usunąć tę cechę z modelu w celu poprawienia jego jakości.

Wyniki i dyskusja

Wygenerowano dwa modele neuronowe: pierwszy model do analiz przeżywalności w 30 roku (M30) oraz drugi model do analiz przeżywalności w 40 roku (M40). Struktura modeli M30 i M40 przyjęła postać 18:18-36-36-1.

W tabeli 3 umieszczono podstawowe parametry wygenerowanych modeli M30 i M40, natomiast w tabeli 4 przedstawiono statystykę klasyfikacji modelu M30 i M40 w zależności od stanu wyjścia TAK lub NIE. W tabeli 5 zaprezentowano wyniki analizy wrażliwości sieci.

Niedbała, G., Korzeniewicz, R. (2018). Wyznaczanie istotności cech biometrycznych do predykcji przeżywalności sosny zwyczajnej (*Pinus sylvestris* L.) z użyciem metod modelowania neuronowego. *Nauka Przyr. Technol.*, 12, 3, 297–307. <http://dx.doi.org/10.17306/J.NPT.00261>

Tabela 3. Parametry modeli neuronowych

Model	Typ	Jakość uczenia	Jakość walidacji	Jakość testowania	Błąd uczenia	Błąd walidacji	Błąd testowania	Metoda uczenia
M30	MLP 18:18-36-36-1:1	0,7215	0,70503	0,69784	0,62019	0,60799	0,59941	BP45b
M40	MLP 18:18-36-36-1:1	0,7338	0,71942	0,67625	0,59247	0,53478	0,79209	BP82b

Tabela 4. Statystyka klasyfikacji dla modelu M30 i M40

Typ odpowiedzi	Przeżywalność dla modelu M30		Przeżywalność dla modelu M40	
	NIE	TAK	NIE	TAK
Procentowo				
Poprawne (%)	70,2	74,3	72,2	72,6
Niepoprawne (%)	29,8	25,7	27,8	27,4
Nieznane (%)	0	0	0	0
Liczbowo				
Poprawne	436	228	507	164
Niepoprawne	185	79	195	62
Nieznane	0	0	0	0
Wszystkie	621	307	702	226

Na podstawie analiz, których wyniki zawarte są w tabeli 5, wykreślono powierzchnie odpowiedzi sieci dla modeli M30 i M40. W modelu M30 uwzględniono dwie najważniejsze cechy o randze 1 oraz 2, czyli średnicę drzewa w czwartym roku życia (d4) oraz średnicę drzewa w piątym roku życia (d5). Na modelu M40 wykazano istotność tych samych cech d4 i d5, co na modelu M30. Na rycinach 1 i 2 zaprezentowano relację pomiędzy najważniejszymi cechami w obydwu modelach, tj. d4 i d5, a wyjęciem sieci w postaci przeżywalności w 30 i 40 roku. Dane wyjściowe miały postać binarną – TAK/NIE i były prezentowane dla sieci w postaci lingwistycznej (słownej).

W ostatnim etapie analiz określono pole powierzchni pod krzywą ROC. Dla modelu M30 pole powierzchni wyniosło 0,789687 (ryc. 3), natomiast dla modelu M40 pole powierzchni wyniosło 0,79231 (ryc. 4).

W wyniku przeprowadzonych analiz wygenerowano dwa modele neuronowe – M30 dla analiz przeżywalności w 30 roku oraz model M40 dla analiz przeżywalności w 40 roku (tab. 3). Sieci bazowały na strukturze perceptronu wielowarstwowego MLP z dwoma ukrytymi warstwami. Wygenerowane modele odznaczały się błędami dla wszystkich zbiorów (uczącego, testowego i walidacyjnego) na podobnym poziomie, tj. 0,53–0,79. W każdym przypadku zastosowano tę samą metodę uczenia sieci, którą była wsteczna propagacja błędów.

Tabela 5. Ocena analizy wrażliwości sieci neuronowych

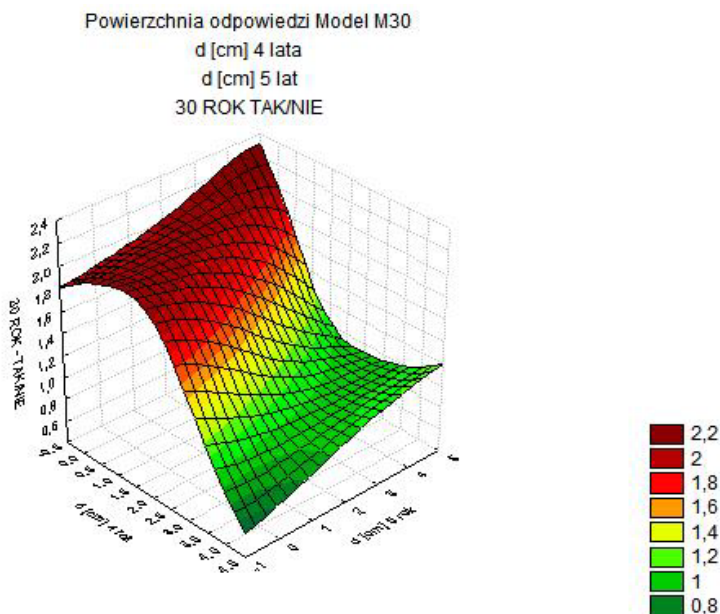
Cecha	Model M30		Model M40	
	iloraz	ranga	iloraz	ranga
h2	1,002319	8	0,97802	15
d2	1,002324	7	0,97885	14
h3	1,002662	6	0,98779	12
d3	1,006011	4	1,001357	5
h4	0,996246	9	0,99086	10
d4	1,034890	1	1,071498	1
h5	1,007413	3	1,024719	3
d5	1,020495	2	1,042421	2
h6	0,99143	12	0,992850	9
d6	1,004218	5	1,015857	4
h7	0,99226	11	0,997517	7
d7	0,98942	15	0,98832	11
h8	0,98471	17	0,97952	13
d8	0,98126	18	0,97581	16
h9	0,99614	10	0,993219	8
d9	0,98614	16	1,000905	6
h10	0,98955	14	0,96807	18
d10	0,98979	13	0,97253	17

W tabeli 4 zestawiono wyniki klasyfikacji odpowiedzi dla wygenerowanych modeli M30 i M40. W modelu M30 poprawne odpowiedzi dla opcji „NIE” przyjęły wartość 70,2%. Natomiast poprawne odpowiedzi dla opcji „TAK” przyjęły wyraźnie wyższą wartość 74,3%. W kolejnej analizie wyznaczono wartości klasyfikacji dla kolejnego modelu. W modelu M40 poprawne odpowiedzi dla opcji „NIE” przyjęły wartość 72,2%. Natomiast poprawne odpowiedzi dla opcji „TAK” wyniosły 72,6%.

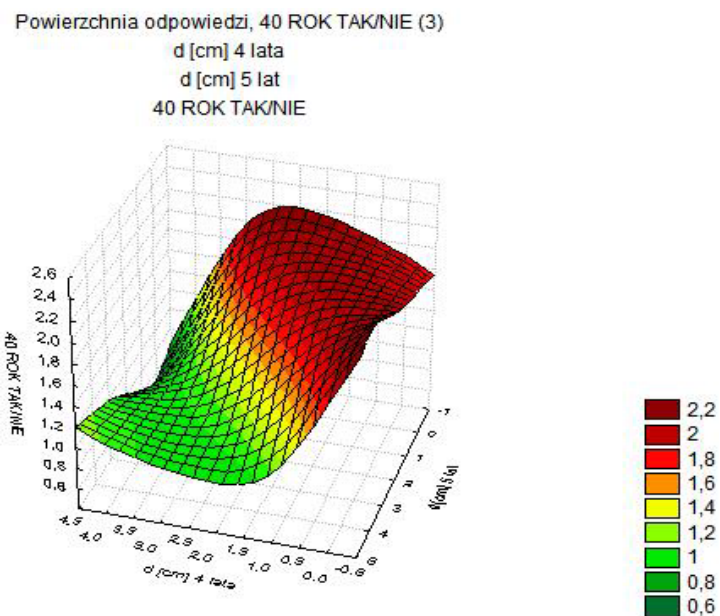
Kolejnym etapem pracy było przeprowadzenie analizy wrażliwości sieci neuronowej (tab. 5). Obydwa modele wskazały te same, najważniejsze cechy. W analizie wykazano, że najważniejsze cechy biometryczne w predykcji przeżywalności drzew sosny zwyczajnej to średnica w czwartym (d4 – ranga 1) i piątym (d5 – ranga 2) roku życia drzewa. Co ciekawe, na trzecim miejscu pod względem istotności (ranga 3) znalazła się wysokość w piątym roku życia drzewa (h5).

W ostatnich krokach wykreślono powierzchnię odpowiedzi sieci dla obydwu modeli oraz wykreślono krzywą ROC. Pole powierzchni pod krzywą ROC dla modelu M30 wyniosło 0,7896, natomiast dla modelu M40 wartość ROC była nieznacznie wyższa i wyniosła 0,7923. Wartości pola pod krzywą ROC mogą zawierać się w przedziale od

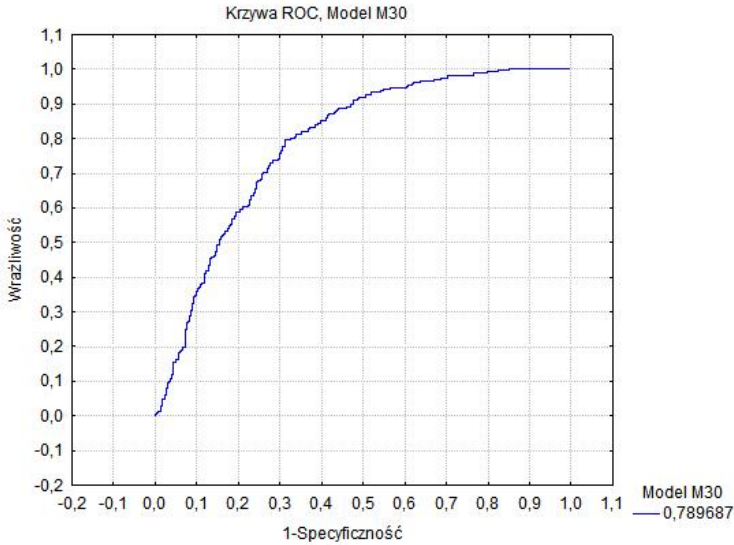
Niedbała, G., Korzeniewicz, R. (2018). Wyznaczanie istotności cech biometrycznych do predykcji przeżywalności sosny zwyczajnej (*Pinus sylvestris* L.) z użyciem metod modelowania neuronowego. Nauka Przyr. Technol., 12, 3, 297–307. <http://dx.doi.org/10.17306/J.NPT.00261>




Ryc. 1. Powierzchnia odpowiedzi sieci M30 dla dwóch zmiennych niezależnych w postaci d_4 i d_5



Ryc. 2. Powierzchnia odpowiedzi sieci M40 dla dwóch zmiennych niezależnych w postaci d_4 i d_5



Ryc. 3. Wykres krzywej ROC dla modelu M30



Ryc. 4. Wykres krzywej ROC dla modelu M40

0 do 1 lub w odniesieniu procentowym od 0 do 100%. Otrzymane wyniki oscylują w podobnych wartościach i są bliskie wartości 0,8. Oznacza to, że w blisko 80% obydwie modele dokonują właściwej klasyfikacji.

Wnioski

1. Przeprowadzone wnioskowanie za pomocą wygenerowanego modelu neuronowego M30 i M40 z użyciem analizy wrażliwości sieci, wskazało najważniejsze cechy biometryczne w predykcji przeżywalności drzew sosny zwyczajnej. Są to średnica w czwartym (d4 – ranga 1) i piątym (d5 – ranga 2) roku życia drzewa.

2. Model M30 i M40 wykazał także wysoką, trzecią rangę dla cechy wysokości w piątym roku życia – h5.

3. Na podstawie statystyki klasyfikacji można przyjąć, że wygenerowane modele klasyfikują z dokładnością M30 – 70,2% do 74,3%, M40 – 72,2% do 72,6%.

4. Modele neuronowe można zastosować do kształtowania struktury drzewostanów sosny zwyczajnej.

Literatura

- Ceitel, J. (1994). Wpływ więzby sadzenia sosny zwyczajnej (*Pinus sylvestris* L.) na wzrost i procesy rozwojowe w I klasie wieku. Rogów: Mater. Sesji Naukowej „Nauka - Doświadczalnictwo – Praktyka Leśna” 17.06.1994.
- Drozdowski, S. (2013). Modelowanie procesów odnowieniowych w lesie naturalnym. Rozprawy Naukowe i Monografie (T. 441). Warszawa: Wyd. SGGW.
- Duch, W., Korbicz, J., Rutkowski, L., Tadeusiewicz, R. (red.). (2000). Biocybernetyka i inżynieria biomedyczna 2000. Tom 6: sieci neuronowe. Warszawa: Akad. Oficyna Wyd. Exit.
- Grahovac, J., Jokić, A., Dodić, J., Vućurović, D. i Dodić, S. (2016). Modelling and prediction of bioethanol production from intermediates and byproduct of sugar beet processing using neural networks. *Renew. Energ.*, 85, 953–958. <https://doi.org/10.1016/j.renene.2015.07.054>
- Jaworski, A. (2004). Podstawy przyrostowe i ekologiczne odnawiania oraz pielęgnacji drzewostanów. Warszawa: PWRiL.
- Kliczkowska, A., Zielony, R. (2012). Regionalizacja przyrodniczo-leśna Polski 2010. Warszawa: Centrum Inf. Lasów Państw..
- Koszela, K., Przybył, J., Kujawa, S., Kozłowski, R. J., Przybył, K., Niedbała, G., Zaborowicz, M. (2016). IT system for the identification and classification of soil valuation classes. *Proceedings of SPIE*, t. 10033. <https://doi.org/10.1117/12.2244066>
- Korzeniewicz, R. (2006). Wzrost i stosunki konkurencyjne wybranych gatunków drzew leśnych w ciągu 30 lat na powierzchniach doświadczalnych w Leśnym Zakładzie Doświadczalnym Siemianice. Maszynopis. Poznań: AR.
- Mishra, S., Mishra, D., Santra, G.H. (2016). Applications of machine learning techniques in agricultural crop production: A review paper. *Indian J. Sci. Technol.*, 9(38). <https://doi.org/10.17485/ijst/2016/v9i38/95032>
- Niedbała, G., Korzeniewicz, R. i Szmyt, J. (2010). Analiza możliwości wykorzystania sztucznych sieci neuronowych do szacowania siły konkurencji wewnątrzgatunkowej w trzydziestoletnich drzewostanach brzozy brodawkowatej (*betula pendula roth*). *Technika Rolnicza Ogrodnicza Leśna*, 4, 19–22. Pobrano z http://www.pimr.poznan.pl/trol4_2010/GN4_2010.pdf
- Niedbała, G., Mioduszevska, N., Mueller, W., Boniecki, P., Wojcieszak, D., Koszela, K., Przybył, K. (2016). Use of computer image analysis methods to evaluate the quality topping sugar beets with using artificial neural networks. *Proc. SPIE 10033* (s. 100332M). Chengdu: Eighth International Conference on Digital Image Processing (ICDIP 2016). <https://doi.org/10.1117/12.2244875>

Szymański, S. (1964). Przebieg procesu naturalnego wydzielenia się drzew w niepielęgowanych młodnikach sosnowych. *Sylvan*, 108 (1), s. 15–31.

Szymański, S. (1982). Wzrost niektórych gatunków drzew leśnych w pierwszych 10 latach życia na siedlisku boru mieszanego świeżego. *Sylvan* 126 (7), 11–29

Szymański, S. (1996). Ekologia sosny zwyczajnej (*Pinus sylvestris* L.). *Sylvan*, 140 (11), 5–10

Wojciechowski, T., Niedbała, G., Czechłowski, M., Nawrocka, J. R., Piechnik, L., Niemann, J. (2016). Rapeseed seeds quality classification with usage of VIS-NIR fiber optic probe and artificial neural networks. Conference: 2016 International Conference on Optoelectronics and Image Processing (ICOIP), At 2016 International Conference on Optoelectronics and Image Processing (ICOIP). <https://doi.org/10.1109/OPTIP.2016.7528517>

DETERMINING THE SIGNIFICANCE OF BIOMETRIC FEATURES FOR PREDICTING THE SURVIVABILITY OF PINE (*PINUS SYLVESTRIS* L.) WITH THE USE OF NEURAL MODELLING METHODS

Abstract

Introduction. Scots pine plays a special role in Poland, both in terms of nature and economy. An attempt to use neural networks to determine the most important biometric feature, which enables prediction of survivability, may have high utilitarian values. Therefore, the aim of the study was to build a predictive neural model, designed to determine the most important biometric features of trees (scots pine) growing in a forty-year-old stand, which determine the survival and occupied biosocial position.

Material and methods. In order to realize the aim of the study, the collected empirical data from the first ten years and from the thirty and forty years of age of the trees in an unattended stand were analyzed. The research material comes from a permanent research area located in the Siemiąnce Experimental Forest District (Forest Experimental Department of Poznań University of Life Sciences). Independent variables – diameter and height of trees (each year), were used to build the model.

Results. Two neural models were generated. The first model for survivability analyses in the year 30 (M30) and the second model for survivability analyses in the year 40 (M40). The structure of models m30 and m40 took the form

18:18-36-36-36-1. The generated models were based on multilayer neural network MLP with two hidden layers.

Conclusions. The conclusion drawn with the aid of a generated neural model with the use of net sensitivity analysis indicated the most important biometric features in the prediction of the survivability of common scots pine trees. These are the diameter in the fourth (d4 – rank 1) and fifth (d5 – rank 2) years of age of the tree.

Keywords: prediction, neural model, scots pine, intra-species competition, survivability.

Niedbała, G., Korzeniewicz, R. (2018). Wyznaczanie istotności cech biometrycznych do predykcji przeżywalności sosny zwyczajnej (*Pinus sylvestris* L.) z użyciem metod modelowania neuronowego. *Nauka Przyr. Technol.*, 12, 3, 297–307. <http://dx.doi.org/10.17306/J.NPT.00261>

Adres do korespondencji – Corresponding address:

Gniewko Niedbała, Instytut Inżynierii Biosystemów, Wydział Rolnictwa i Bioinżynierii, Uniwersytet Przyrodniczy w Poznaniu, ul. Wojska Polskiego 50, 60-627 Poznań, e-mail: gniewko@up.poznan.pl

Zaakceptowano do opublikowania – Accepted for publication:

09.08.2018

Do cytowania – For citation:

Niedbała, G., Korzeniewicz, R. (2018). Wyznaczanie istotności cech biometrycznych do predykcji przeżywalności sosny zwyczajnej (*Pinus sylvestris* L.) z użyciem metod modelowania neuronowego. *Nauka Przyr. Technol.*, 12, 3, 297–307. <http://dx.doi.org/10.17306/J.NPT.00261>