

WIKTOR TRACZ

Wykorzystanie Sieci Neuronowych wspomagających SIP w analizach przestrzennych w leśnictwie

Use of GIS supported by Artificial Neural Networks in spatial analyses in forestry

ABSTRACT

Complex, new and insufficiently recognised issues that appear as the result of multifunctional approach towards forest management need application of sophisticated techniques and analytical methods supporting the State Forests' IT Systems (State Forests Information System SIL) and Geographical Information System GIS). The authors take efforts to elucidate the usefulness and effectiveness of one of Artificial Intelligence methods - Artificial Neural Networks which support GIS in spatial analyses in forestry.

KEY WORDS

forestry, spatial analysis, GIS, Artificial Neural Networks

Wprowadzenie

Różne techniki informatyczne są od dawna wykorzystywane przez Lasy Państwowe (LP). Tak jak stosowany już System Informatyczny Lasów Państwowych (SILP) Systemy Informacji Przestrzennej (SIP) bardzo efektywnie i skutecznie wspomagają procesy decyzyjne w rozwiązywaniu różnych problemów w leśnictwie. Potrzeba wykorzystania SIP w zarządzaniu gospodarką leśną w Polsce jest oczywista, a korzyści z tego płynące są ogromne. W zagadnieniach bardziej złożonych, nowych i mało zbadanych, które pojawiają się w związku z wielofunkcyjnym podejściem do gospodarki leśnej, zachodzi potrzeba wykorzystania wyrafinowanych technik i metod analitycznych wspomagających SILP i SIP. Metody Sztucznej Inteligencji (SI) są jednymi z takich technik. Stosowanie metod SI razem z SIP w jednym systemie wspomagania decyzji zwiększa możliwości analityczne i wydaje się być bardzo pomocne w rozwiązywaniu wielu słabo ustrukturalizowanych problemów z zakresu leśnictwa.

Prezentowana praca podejmuje próbę zbadania celowości i efektywności wykorzystania jednej z metod SI – Sztucznych Sieci Neuronowych (SN) – wspomagających SIP w rozwiązywaniu złożonych problemów przestrzennych leśnictwa.

Wspomaganie rozwiązywania problemów przestrzennych leśnictwa

Lasy Państwowe zajmują jedną czwartą obszaru kraju i rozmieszczone są, chociaż nierównomiernie, na całej jego powierzchni. Warunki klimatyczne, glebowe, środowiskowe itp. są różne

WIKTOR TRACZ

Katedra Urządzania Lasu, Geomatyki i Ekonomiki
Leśnictwa, Wydział Leśny SGGW
ul. Nowoursynowska 159
02-776 Warszawa
wiki@witch.sggw.waw.pl

w różnych miejscach kraju. Las jako składnik żywej przyrody jest układem skomplikowanym i stale zmieniającym się. Współczesna gospodarka leśna pełni nie tylko funkcje produkcyjne, ale również rekreacyjne ochronne, edukacyjne. Wszystko to komplikuje podej-

można trafnych i skutecznych decyzji przy zarządzaniu leśnictwem i wymusza stosowanie sprawnych pomocniczych narzędzi i metod.

Na każdym szczeblu struktury LP (nadleśnictwo, Regionalna Dyrekcja LP, Dyrekcja Generalna LP) decydenci mają do czynienia z problemami bardziej lub mniej złożonymi. Dlatego w LP istnieje potrzeba stosowania różnych pod względem zaawansowania technik i systemów informatycznych [Tracz 2001].

Systemy Informacji Przestrzennej są oparte na wykorzystaniu technik komputerowych i umożliwiają gromadzenie, udostępnianie, analizowanie i prezentację danych przestrzennych. Dzięki tym bogatym możliwościom są niezastąpionymi narzędziami wspomagającymi zarządzanie w leśnictwie. W leśnictwie polskim SIP stosowane są od połowy lat dziewięćdziesiątych [Okła 2000].

Niewątpliwie najcenniejszą właściwością SIP jest możliwość analiz. SIP realizują przede wszystkim analizy przestrzenne i analizy danych przestrzennych, np. analizy sieciowe, buforowanie, analizy sąsiedztwa. Badając dowolny problem często tworzy się model, który jest próbą formalizacji występujących w nim zależności. Modele umożliwiają lepsze zrozumienie problemu oraz dostarczają kryteriów i sposobów jego analizy. Systemy informacji przestrzennej też opierają się na modelu. Odzworowuje on rzeczywistość w postaci wyodrębnionych warstw informacyjnych, które można prezentować w różny sposób. Można też tworzyć nowe warstwy informacyjne przez przekształcenia posiadanych warstw zgodnie z algorytmem rozwiązywania danego problemu, korzystając z możliwości zawartych w oprogramowaniu SIP.

Złożoność niektórych problemów przyrodniczo-leśnych wymusza wykorzystanie modeli, które współpracują z SIP. Modele te mogą opisywać pewną część rozwiązywanego problemu i mogą być zapisane np. w formie równań, układów równań lub formuł matematycznych. Model może stanowić końcowy etap w rozwiązaniu problemu, wtedy dane wyjściowe są wizualizowane lub, gdy model dostarcza rozwiązań pośrednich, są wykorzystywane do dalszych analiz w SIP.

Istnieje jednak grupa zagadnień natury przestrzennej, które nie dają się rozwiązać za pomocą tylko SIP lub modeli matematycznych połączonych z SIP. Zagadnienia takie mają najczęściej charakter nieliniowy, a konwencjonalne nieliniowe modele matematyczne opisujące je mogą nie dawać zadowalających wyników. Rozwiązując problemy przyrodniczo-leśne dość często nie dysponujemy potrzebną wiedzą, jest ona wyrażona tylko w postaci symbolicznej lub jest niepewna czy niekompletna, a koszt pozyskania całej informacji jest duży. Trudno jest wtedy zbudować właściwy model. Nawet do modelowania nieliniowego wprowadzane są pewne ograniczenia i uproszczenia wielu ważnych parametrów, co prowadzi do nieadekwatnego opisu rzeczywistości [Openshaw 1997].

Możliwość wykorzystania SN razem z SIP w analizach przestrzennych

W leśnictwie też istnieje grupa zagadnień mało ustrukturalizowanych, a zatem trudnych do rozwiązania. Do ich rozwiązania, jak się wydaje, najlepiej nadają się metody Sztucznej Inteligencji, które mogą być stosowane wtedy, gdy:


- nie dysponujemy całą wiedzą potrzebną do rozwiązania danego problemu, a czas rozwiązania metodami znanymi (np. algorytmicznymi) jest zbyt długi;
- dane są nie tylko w postaci numerycznej (np. 37 h, 128,45 m, 19,7 kg, itd.), ale też w postaci symbolicznej (np. Bk, So, Bśw, zielony, wilgotne, dużo, itd.);
- informacja jest dostępna raczej w postaci heurystyk niż dobrze zdefiniowanych procedur algorytmicznych;

- wiedza o przedmiocie nie jest pełna, a koszt pozyskania niezbędnych ekspertyz jest duży;
- wiedza jest niepewna.

Przy rozwiązywaniu trudnych problemów metodami Sztucznej Inteligencji, dane przestrzenne poddawane są odpowiedniemu przetwarzaniu i dalej mogą być wykorzystane w SIP. Sieci Neuronowe mogą realizować następujące przetwarzania [Zieliński 2000]:


- optymalizację, a w tym rozwiązywanie liniowych i nieliniowych równań;
- klasyfikację, która realizowana jest przez podział zbioru wejściowego na klasy lub kategorie skojarzenia każdego wejścia z kategorią;
- sterowanie, realizowane inteligentnie bez konieczności opracowania modelu, oparte wyłącznie na doświadczeniu;
- przypominanie polegające na: odzyskiwaniu (albo interpretowaniu) zmagazynowanych w SN informacji, obliczaniu wyjścia dla danego wejścia;
- rozpoznawanie, rozumiane jako klasyfikowanie wejścia, mimo że nie odpowiada ono żadnemu z przechowywanych wzorców;
- skojarzenie, realizowane w następujących wariantach: skojarzenie uszkodzonego (zdeformowanego) wejścia (albo wywołania) z najbliższym przechowywanym wzorcem, skojarzenie między parą wzorców, diagnostyka, analiza;
- estymację, czyli realizacja następujących zadań: aproksymacja, interpolacja, filtrowanie, predykcja, prognozowanie.

Wyżej wymienione przetwarzania realizowane przez SN mogą dostarczać rozwiązań przeznaczonych bezpośrednio do prezentacji w SIP lub wyników pośrednich, które mogą być wykorzystane w dalszych analizach realizowanych za pomocą SIP. Taki rodzaj współpracy nazywany jest szeregowym (ryc. 1). SN i SIP mogą też współpracować równolegle (ryc. 2). Sieci neuronowe tak jak i SIP budowane są obecnie jako systemy otwarte. Pozwala to na łatwiejszą i szybszą ich integrację między sobą oraz z innymi technikami w jednym systemie wspomagania.



Ryc. 1.

Współpraca szeregową
Linear cooperation



Ryc. 2.

Współpraca równoległa
Parallel cooperation

Czy w leśnictwie polskim decydenci mają do czynienia z problemami trudnymi? Dokładniej mówiąc, czy rozwiązując problemy przestrzenne zawsze posiadają wszystkie niezbędne dane i czy te dane są pewne, czy zawsze znany jest algorytm postępowania, czy są wystarczające dotychczas stosowane techniki informatyczne? Czy w praktyce leśnej w Polsce występują takie zagadnienia przestrzenne, które można byłoby rozwiązać wykorzystując SIP wspomagane metodami sztucznej inteligencji? Odpowiedź na te pytania daje ankieta „Potrzeby użytkowników Leśnej Mapy Numerycznej w Lasach Państwowych” przeprowadzona przez Dyрекcję Generalną Lasów Państwowych. Ankieta miała za zadanie określenie potrzeb i problemów, występujących w zarządzaniu gospodarką leśną, użytkowników SIP lub w niedalekiej przyszłości Leśnej Mapy Numerycznej. Większość zgłoszonych w ankiecie problemów można rozwiązać za pomocą technologii SIP. Ale występują też i takie zagadnienia, w których narzędzia i analizy SIP nie są wystarczające. Wyraźnie wskazują także na to opinie ekspertów z poszczególnych dziedzin leśnictwa, które zostały sporządzone w celu interpretacji zgłoszonych w ankiecie potrzeb. W pracy podjęto próbę przetestowania możliwości zastosowania sieci neuronowej wspomagającej SIP w rozwiązaniu trudnych zagadnień zarządzania w Lasach Państwowych. Wybrano zagadnienie prognozowania rozwoju populacji brudnicy mniszki (*Lymantria monacha* L.) jako reprezentację ważnych zagadnień ochrony lasu.

Przykład wykorzystania SN wspomagającej SIP

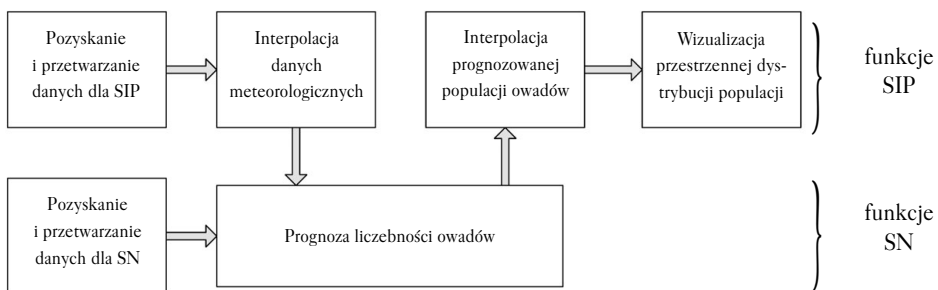
Monitoring brudnicy mniszki z zastosowaniem pułapek feromonowych jest stosowany w Polsce w celu stwierdzenia obecności tego szkodnika sosny w terenie, śledzenia przebiegu jego rójki i długoterminowych trendów gęstości populacji oraz wczesnego wykrycia obszarów kompleksów leśnych o zwiększonej liczebności populacji tego owada [Szujecki 1995]. Prognoza zagrożenia przez brudnicę mniszkę oparta jest głównie na liczbie odłowionych motyli do pułapek feromonowych, rzadziej na liczbie samic znalezionych na wyznaczonych grupach drzew kontrolnych lub obserwacji samic podczas jednorazowego przejścia przez drzewostan wzdłuż transektu. Prognoza taka jednak nie uwzględnia innych ważnych czynników wpływających na stan populacji owada [Kolk 2000]. Do takich czynników należą:

- kondycja drzewostanu (jego stan fizjologiczny), a w związku z tym jego odporność na żery;
- stan populacji owadów pasożytniczych, grzybów oraz gryzoni leśnych i dzików;
- stan fizjologiczny populacji owadów gradacyjnych;
- cykliczność wystąpień;
- aktywność słońca;
- fazy gradacji;
- zwalczania lub jego braku w poprzednich latach.

Celem badań było sprawdzenie efektywności wykorzystania sieci neuronowej wspomagającej SIP (wykonany w Standardzie Leśnej Mapy Numerycznej) do prognozowania zagrożenia brudnicą mniszką. Budując model neuronowy zagadnienia prognozowania starano się z jednej strony w pełni wykorzystać obecny stan wiedzy merytorycznej, z drugiej strony uwzględnić lokalne warunki nadleśnictwa testowego oraz wykorzystać dane już istniejące, gromadzone na różnorodne potrzeby w Lasach Państwowych lub istniejące dane spoza LP. W badaniach zostały wykorzystane dane empiryczne pochodzące z Nadleśnictwa Skarżysko-Kamienna, w którym założono system informacji przestrzennej, zbudowany w Standardzie Leśnej Mapy Numerycznej.

Model prognozowania zagrożenia przez brudnicę mniszkę uwzględniał takie czynniki, jak odporność drzewostanu na żery owada, stan fizjologiczny populacji brudnicy mniszki, warunki meteorologiczne. Nie mniej istotne czynniki wpływające na stan populacji owada – stan populacji owadów pasożytniczych, aktywność słońca, zwalczanie – nie zostały włączone do modelu, z powodu braku odpowiednich danych. W badanym okresie na terenie Nadleśnictwa Skarżysko-Kamienna nie wystąpiło zagrożenie, a więc nie były też przeprowadzone zabiegi zwalczające. Wychodząc ze spiralnego modelu lasu [Manion 1981] odporność drzewostanu została określona przez takie zmienne jak typ siedliskowy lasu, typ gleby, wystawę i nachylenie terenu. Dane meteorologiczne to średnia miesięczna temperatura i suma opadów w kwietniu i maju. Stan fizjologiczny populacji brudnicy mniszki jest określony przez liczbę odłowionych motyli brudnicy mniszki do pułapek feromonowych. Typ gleby i siedliskowy typ lasu dla testowanych wydzieleń zostały odczytane z bazy danych SILP Nadleśnictwa Skarżysko-Kamienna. Nachylenie i wystawa terenu były uzyskane z warstw informacyjnych utworzonych w SIP z modelu numerycznego terenu dla nadleśnictwa. Dane o liczbie owadów brudnicy mniszki odłowionych w poszczególnych latach do pułapek feromonowych oraz miejsca ich rozmieszczenia zostały udostępnione przez Nadleśnictwo Skarżysko-Kamienna. Dane meteorologiczne pozyskane były z Instytutu Meteorologii i Gospodarki Wodnej (IMI GW). Wartości temperatury zostały zmierzone w dwóch, a wartości opadów w trzech stacjach (posterunkach) meteorologicznych rozmieszczonych w okolicach nadleśnictwa testowego. Warunki meteorologiczne są bardzo istotnymi czynnikami warunkującymi rozwój populacji owadów, dlatego należało określić bardziej dokładne wartości tych danych w każdym z wybranych wydzieleń. W tym celu w SIP została utworzona warstwa punktowa pomiarów meteorologicznych i wykonana interpolacja (ekstrapolacja) metodą IDW [Magnuszewski 1999], [ArcView Interpolation 1996] znanych wartości danych meteorologicznych na obszar całego nadleśnictwa. Przepływ danych przedstawia rycina 3.

Preprocessing danych, wykorzystanych do uczenia sieci neuronowych, dotyczył ich kompletności i reprezentatywności pod względem zakresu czasowego (1996-2000), gatunku panującego (So), wieku (40-80 lat), braku zniszczeń pułapek i wartości zerowych. W ostateczności liczba przypadków wynosiła 168. Każdy z nich zawierał takie dane jak: średnia miesięczna temperatura i suma miesięcznych opadów z kwietnia i maja, typ siedliskowy lasu, typ gleby, wystawa, nachylenie terenu i liczba motyli brudnicy mniszki odłowionych do pułapek feromonowych w roku poprzedzającym rok prognozowany. Zmienna wyjściowa, czyli zmienna prognozowana, to liczba motyli brudnicy mniszki w roku bieżącym.



Ryc. 3.

Schemat przepływu danych
Data flow chart

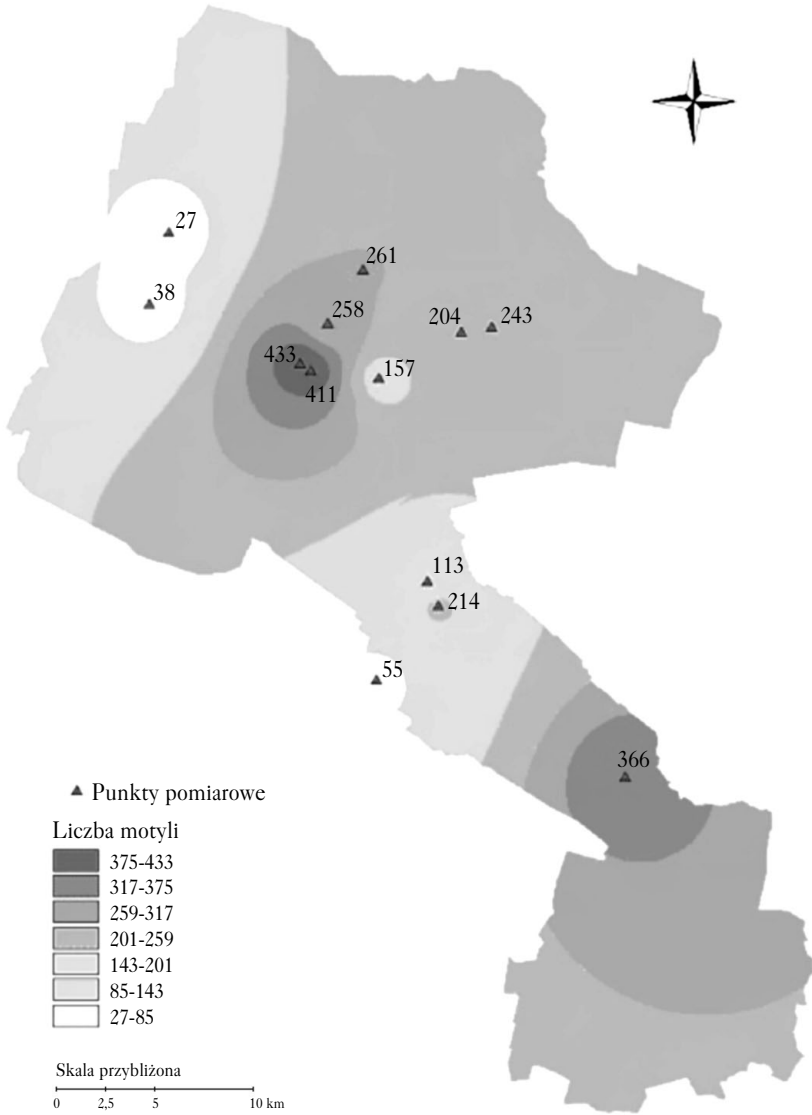
Nauczanie lub trenowanie sieci neuronowej polega na obliczeniu takich wewnętrznych wartości sieci o zadanej architekturze i parametrach uczących, aby mogła ona jak najlepiej dopasować zaprezentowane jej dane wejściowe (przesłanki) do danych wyjściowych (prognoza). Im dopasowanie jest lepsze, tym mniejszy jest błąd sieci, a większa jej dobroć i tym dokładniejsze będą oszacowania danych testowych. W badaniach obecnych wykorzystany został symulator sztucznej sieci neuronowej firmy StatSoft Inc. Statistica Neural Networks PL. Program udostępnia kilka wskaźników oceny dobroci zbudowanego modelu neuronowego. Dla zagadnień regresyjnych, do których należy badany problem, takimi wskaźnikami są: błąd RMS, iloraz odchylenia, korelacja, rozkład wartości wag, analiza wrażliwości. Do oceny dobroci modelu i co za tym idzie większej trafności prognozy wykorzystuje się wszystkie wymienione wskaźniki. Średniokwadratowy błąd RMS określa przeciętne odchylenie wartości teoretycznych (obliczonych przez sieć) od wartości rzeczywistych. Za najlepsze wskaźniki dobroci nauczonej sieci uważa się iloraz odchylenia standardowego błędów i odchylenia standardowego danych oraz korelację między wartościami rzeczywistymi i obliczonymi przez sieć. Im iloraz odchylenia jest bliższy wartości zero, a korelacja jedności, tym dokładniej prognozuje nauczona sieć. Sieci dobrze nauczonej odpowiadają wykresy słupkowe wskazujące na wyraźną dywersyfikację wartości wag (wykresy wielomodalne). Natomiast sieci źle nauczone (lub nauczone niecałkowicie) charakteryzują się równomiernym rozkładem wartości wag. Analiza wrażliwości z kolei umożliwia ocenę wagi każdej z włączonych do modelu zmiennych, z którą oddziałują one na wynik końcowy.

Zbiór przypadków został podzielony na podzbiór uczący (130 przypadków), podzbiór walidacyjny (32 przypadków) i podzbiór testowy (6 przypadków). W trakcie uczenia sieci wykorzystywany jest podzbiór uczący. Zbiór testowy służy do oceny dobroci nauczonej sieci. W wyniku prób za najlepszą uznano sieć MLP z dwoma warstwami ukrytymi. W uczeniu sieci zastosowano algorytm wstecznej propagacji błędu. Dla podzbioru testowego otrzymano następujące wartości wskaźników dobroci: błąd RMS – 17,7; iloraz odchylenia – 0,23; korelacja – 0,97; histogram wartości wag (inaczej rozkład wag) nie jest rozkładem normalnym o wartości średniej zero. Analiza wrażliwości pokazała, że najmniejsze znaczenie (wagę) w prognozie ma zmienna określająca temperaturę w maju. Dlatego ostateczny model sieci neuronowej nie uwzględnia tej zmiennej.

Prognozowana przez sieć neuronową liczba owadów dotyczy tylko drzewostanów, w których zostały wyłożone pułapki feromonowe. Aby uzyskać prognozę liczby spodziewanych owadów w pozostałych wydzieleniach wykonano interpolację wartości obliczonych przez sieć neuronową. W wyniku tej operacji, wykonanej za pomocą SIP, otrzymano warstwę informacyjną rozkładu prawdopodobnego występowania motyli brudnicy mniszki na całym analizowanym obszarze. Dystrybucję przestrzenną prognozy uzyskanej za pomocą SN po interpolacji w SIP podano na rycinie 4. Prognozę sporządzono dla roku, dla którego istniały dane rzeczywiste. Weryfikacji trafności prognozowania przez SN dokonano przez porównanie danych rzeczywistych z danymi z prognozy (podzbiór testowy). Różnica między tymi danymi wyniosła średnio 7,27%.

Podsumowanie

Analiza wskaźników dobroci nauczonej sieci wskazuje na wiarygodność modelu prognozowania zagrożenia brudnicą mniszką. Z punktu widzenia potencjalnych możliwości Sieci Neuronowych uzyskany model dla danego problemu nie można jednak uznać za ostateczny i w pełni kompletny. 130 przypadków, na podstawie których sieć zbudowała model zagadnienia to za mało.



Ryc. 4.

Przestrzenna dystrybucja populacji motyli brudnicy mniszki – wynik interpolacji prognozowanych przez SN wartości

Spatial distribution of nun moth populations – results of interpolations by NN values

Liczba kombinacji możliwych do ułożenia z ośmiu zmiennych jest znacznie większa. Aby uznać wyniki prognozy sieci za w pełni wiarygodne, dane uczące muszą opisywać wszystkie przypadki, które mogą wystąpić w rzeczywistości. Wykorzystanie danych z okresu np. 8-10 lat dla 20-25 wydzieleń mogłoby zapewnić wystarczającą ilość informacji, by sieć nauczyła się i rozpoznała większość przypadków. Problem tu występujący jest bardziej problemem kompletności danych i rzetelności ich zbierania niż problemem małych możliwości Sieci Neuronowych. Dane przeznaczone do uczenia sieci, czyli takie, na podstawie których będzie zbudowany model neu-

ronowy zagadnienia, powinny być jak najbardziej pełne i reprezentatywne. Dysponując dobrym modelem można skutecznie prognozować korzystając nawet z danych niekompletnych lub niepewnych.

Wykorzystane do uczenia sieci neuronowej dane wyznaczają pole wiarygodnego zastosowania modelu neuronowego. Dane te dotyczyły drzewostanów sosnowych w wieku 40-80 lat na terenie przeważnie równinnym i rosnących na wybranych siedliskach. Oznacza to, że prognoza sieci będzie reprezentatywna tylko dla tak opisanych drzewostanów, i nie można uznać za poprawną prognozę zagrożenia w drzewostanach w innym wieku niż 40-80 lat, a tym bardziej w terenie górzystym. Dla terenów o innych warunkach meteorologicznych i siedliskowych należałoby pozyskać niezbędne dane i zbudować nowy model neuronowy (nauczyć nową sieć), który byłby reprezentatywny dla tego terenu.

Systemy Informacji Przestrzennej mogą być skutecznie wspomagane Sieciami Neuronowymi w rozwiązywaniu nieliniowych i słabo sformalizowanych problemów leśnictwa. Zastosowany w badaniu rodzaj współpracy polegający na wymianie plików nie jest jedynym możliwym (a na pewno nie jest najbardziej wygodny dla użytkownika), lecz wystarczający do realizacji założeń celu badawczego. Sztuczne Sieci Neuronowe tak jak i SIP są programami komputerowymi, które ciągle są udoskonalane i rozwijane. Podobnie jak oprogramowanie dla SIP, programy-symulatory SN posiadają interfejs programisty (API). Korzystając z niego można stworzyć prosty i przyjazny interfejs, nie wprowadzając użytkownika w szczegóły techniczne, jednocześnie realizując elastyczną i efektywną współpracę obu narzędzi.

Literatura

- ArcView Interpolation. 1996. Plik pomocy do programu ArcView 3.1. ESRI Inc.
- Kolk A., Ślusarski S., Sukovata L. 2000. Prognozowanie występowania ważniejszych szkodników sosny – stan obecny i potrzeby badawcze. Stan i perspektywy badań z zakresu ochrony lasu. Monografia pod redakcją H. Malinowskiego. IBL, Warszawa.
- Magnuszewski A. 1999. GIS w geografii fizycznej. PWN, Warszawa.
- Manion P. 1981. Tree disease concepts. Printice Hall Inc., New York.
- Mulawka Jan J. 1996. Systemy ekspertowe. WNT, Warszawa.
- Okła K. (red.). 2000. System Informacji Przestrzennej w Lasach Państwowych. Podręcznik użytkownika leśnej mapy numerycznej. Bogucki Wydawnictwo Naukowe S. C., Warszawa.
- Openshaw O., Openshaw Ch. 1997. Artificial Intelligence in Geography. John Wiley and Sons.
- Statistica Neural Networks PL. 2001. Dokumentacja do programu. StatSoft Polska Sp. z o. o
- Szmidt A., Luterek R. 1984. Entomologia leśna. Poznań.
- Szujecki A. 1995. Entomologia leśna. Wydawnictwo SGGW, Warszawa.
- Traź W. 2001. Nowoczesne narzędzia wspomagania procesu decyzyjnego w leśnictwie. Sylwan 2: 39-47.
- Zieliński Jerzy S. 2000. Inteligentne systemy w zarządzaniu. Teoria i praktyka. WNT, Warszawa.

SUMMARY

Use of GIS supported by Artificial Neural Networks in spatial analyses in forestry

The complexity of some nature-related and forest issues requires various modelling methods supporting Geographical Information Systems (GIS). However there is a group of complex space-related problems which need specialistic knowledge in order to be solved. We often lack this knowledge expressed in the form of a symbol in solving such problems; it can be either uncertain or incomplete or expensive. The use of Neural Networks (NN) combined with GIS provides greater analytical possibilities and is an efficient tool in solving poorly structured forest-related problems.

The paper attempts to test the use of neural networks supporting GIS- in solving complex problems of Polish forestry. The issue concerning forecasts of the nun moth (*Lymantria monacha* L.) population abundances was chosen to represent important aspects of forest protection.

The model for predicting threat to forests posed by nun moth takes in the factors such as stand resistance to insect feeding, physiological state of nun moth populations, meteorological conditions. In order to make meteorological data more precise, (IDW) method was applied to interpolate the known values of meteorological data for the entire forest district. The neural network was used to predict insect abundances. The data flow is illustrated in Fig. 3.

The goodness indices of the neural network prove the reliability of the model for predicting threat posed by nun moth. The spatial distribution of the prediction after the interpolation in SIP is presented in Fig. 4. The prediction was made for the year, which had real data set. The correctness of the forecast with support of the NN was verified by comparing real data with predicted data (test subset). The difference between these data was on average 7.27%.