

KLASYFIKACJA CHRONIONYCH W POLSCE MOTYLI Z RODZINY *PAPILIONIDAE* Z WYKORZYSTANIEM WYBRANYCH TOPOLOGII NEURONOWYCH

Streszczenie

Celem badań było porównanie zdolności klasyfikacyjnych modeli neuronowych, uczonych dwoma różnymi metodami: wzorcową oraz bezwzorcową. Klasyfikacji poddano wybrane owady należące do rodziny „*Papilionidae*”, które objęte są ochroną prawną na terenie Polski. Neuronowej klasyfikacji dokonano w oparciu o informację zakodowaną w postaci zbioru dwuwymiarowych obrazów owadów. Jako cechy reprezentatywne, stanowiące podstawę do klasyfikacji, przyjęto pięć dominujących kolorów występujących w ubarwieniu motyli. W celu porównawczym wygenerowano dwie topologie neuronowe: sieć typu MLP (ang. *MultiLayer Perceptron*: perceptron wielowarstwowy) uczonej technikami „z nauczycielem” oraz sieć Kohonena, która była uczona metodą „bez nauczyciela”.

1. Wprowadzenie

Praktyczne aplikacje metod sztucznej inteligencji, a w szczególności modelowanie neuronowe, znajdują coraz częściej zastosowanie, również w dyscyplinie inżynieria rolnicza [1, 2]. Istotnym aspektem użytecznym jest wykorzystanie numerycznych symulatorów sztucznych sieci neuronowych do informatycznego wsparcia procesów związanych z przetwarzaniem oraz rozpoznawaniem obrazów cyfrowych. W procesie identyfikacji oraz ekstrakcji wiedzy zakodowanej w postaci graficznej, będącej m.in. kryterium klasyfikacyjnym, ważną rolę odgrywają modele neuronowe, uczone zarówno techniką „z nauczycielem” jak również „bez nauczyciela”. Spośród znanych topologii neuronowych najczęściej zastosowanie znajdują sieci typu MLP (ang. *MultiLayer Perceptron*: perceptron wielowarstwowy) oraz typu Kohonena.

Sieci typu MLP to jednokierunkowe topologie neuronowe uczone tzw. metodą wzorcową, inaczej zwane techniką „z nauczycielem”. Oznacza to, że wektor uczący tworzący strukturę zbioru uczącego zawiera składowe zarówno wejściowe jak również wyjściowe. Poszczególne przypadki uczące stanowią zbiory nie skorelowanych cech, będących sygnałami podawanymi na wejściu sieci, oraz wielkości wyjściowych reprezentujących prawidłową odpowiedź (tę „wiedzę” kojarzy się z nauczycielem, co tłumaczy nazwę omawianej procedury).

Inaczej uczone są jednokierunkowe, dwuwarstwowe sieci Kohonena, zwane często sieciami typu SOFM (ang. *Self-Organizing Feature Maps*: samoorganizujące się mapy cech). W tym przypadku optymalizacja sieci neuronowej odbywa się za pomocą tzw. metody uczenia bezwzorcowej, inaczej zwanej techniką „bez nauczyciela”. Zbiór uczący zawiera jedynie przypadki zawierające składowe wejściowe i nie posiadające zmiennych wyjściowych, tzn. nie jest znany wzorzec odpowiedzi sieci. Tworzony w ten sposób model neuronowy, podczas korekcji wag, zachodzącej w trakcie procesu uczenia, w istocie sam znajduje istniejące prawidłowości występujące w zbiorze uczącym. Ze względu na swą naturę sieć Kohonena podczas uczenia dokonuje jądrowej klasyfikacji w zbiorze danych, stanowiącym zredukowany zbiór uczący (wspomniany brak zmiennych wyjściowych). Jeśli taki zbiór posiada również odpowiedzi, wtedy mogą one być wykorzystane do etykietowania poszukiwanych centrów klasyfikacyjnych (na mapie topologicznej), względnie do dalszej optymalizacji zbu-

dowanego modelu Kohonena z wykorzystaniem algorytmu LVQ (ang. *Learned Vector Quantization*: adaptacyjne kwantowanie wektorowe).


Sieci typu MLP oraz SOFM istotnie różnią się zarówno pod względem budowy, sposobu uczenia, jak również wymagań odnośnie ilości informacji zakodowanej w strukturze zbioru uczącego. Łączy je fakt, że zarazem sieci typu MLP jak i SOFM uznawane są jako wygodne i efektywne instrumenty klasyfikacyjne. Warto zauważyć, że problematyka analizy oraz rozpoznawania obrazów z wykorzystaniem topologii neuronowych jest stosunkowo nowym obszarem zainteresowań badaczy. Obecnie modele neuronowe stanowią uzupełnienie dla klasycznych, a zatem sprawdzonych, metod identyfikacyjnych. Posiadają przy tym pewne pożądane cechy (jak np. szybkość działania), dające istotną przewagę nad technikami tradycyjnymi.

Celem pracy jest porównanie zdolności separacyjnych wymienionych sieci neuronowych, trenowanych z wykorzystaniem tego samego zbioru uczącego. W badaniach wykorzystano zbiór treningowy zbudowany w oparciu o dane graficzne występujące w postaci obrazów cyfrowych przedstawiających motyle chronione na terenie Polski. Wygenerowane modele neuronowe zbudowano w celu dokonania klasyfikacji tych owadów.

2. Materiał badawczy

W związku z obserwowaną tendencją do ilościowego spadku populacji motyli występujących w przyrodzie Polski, owady z rodziny *Papilionidae* objęte są na terenie państwa ochroną prawną. Stanowią one rodzinę dużych motyli dziennych, obejmującą ogółem ok. sześćset gatunków, z których dwanaście występuje w Europie, natomiast cztery można zaobserwować na terenie Polski. Omawiane motyle na ogół występują na terenach otwartych i najczęściej można je spotkać na nasłonecznionych polanach oraz na otwartych stokach górskich. Do krajowych przedstawicieli fauny z rodziny *Papilionidae* należą następujące gatunki:

- *Papilio machano* (L.) paź królowej,
- *Iphiclides podalirius* (L.) paź żeglarz,
- *Parnassius apollo* (L.) niepylak apollo,
- *Parnassius mnemosyne* (L.) niepylak mnemosyna.



Rys. 1. Motyle z rodziny Papilionidae
Fig. 1. Papilionidae butterflies

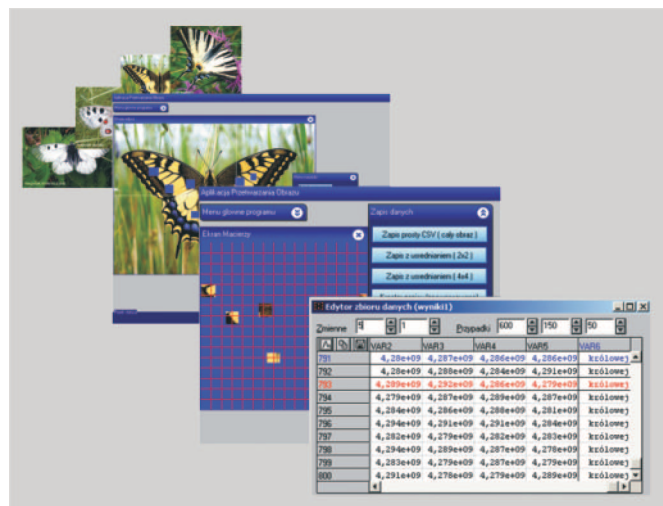
3. Metodyka badawcza

Jako cechy reprezentatywne dla procesu separacyjnego uznano pięć zmiennych wejściowych, stanowiących dominujące kolory oraz artefakty, charakterystyczne dla klasyfikowanych motyli. W celu zbudowania zbioru uczącego posłużono się narzędziem „Próbnik”, zaimplementowanym jako funkcjonalny moduł w wytworzonym systemie informatycznym: „Przetwarzanie Obrazu v.1.0” [3]. Pozwala on na wygenerowanie zbioru wektorów (przypadków) uczących zapisanych w formie właściwej do dalszej „obróbki” z wykorzystaniem pakietu „STATISTICA v. 4.0”. Wytworzony zbiór uczący zawierał osiemset niezależnych wektorów (przypadków), standardowo podzielonych losowo na zbiory: uczący, walidacyjny oraz testowy, w proporcji 600:150:50 (rys. 2). Numeryczne zmienne wejściowe stanowiło pięć odpowiednio zakodowanych barw charakterystycznych [3], natomiast za pomocą nominalnej, czterostanowej zmiennej wyjściowej opisano nazwy klasyfikowanych owadów.

4. Klasyfikacja „wzorcowa”

Do wytworzenia modeli neuronowych wykorzystano moduł „STATISTICA Neural Networks” zaimplementowany w pakiecie „STATISTICA v. 4.0”. W pierwszej kolejności zbudowano sztuczną sieć neuronową typu MLP. Po zaimportowaniu wygenerowanych plików do edytora danych symulatora sieci neuronowych pakietu „STATISTICA v. 4.0” wygenerowano sieć neuronową typu MLP składającą się z trzech warstw i posiadającą strukturę: 5-23-1 (jedna warstwa ukryta, rys. 3). Uczenie przeprowadzono z wykorzystaniem algorytmu wstecznej propagacji błędów BP (ang. *Back Propagation*) w 1000 epokach oraz algorytmu gradientów sprzężonych CG (ang. *Conjugate Gradients*) w 5 sesjach po 800 epok. Na rys. 3 pokazano wykres błędów uczenia sieci dla zbioru uczącego (zaznaczony na niebiesko) oraz dla zbioru walidacyjnego (zaznaczony na czerwono). Na rysunku tym również zaprezentowano zrzuty ekranowe fragmentu zbioru uczącego oraz okna edytora zbioru wygenerowanych modeli neuronowych. Przedstawiono także podstawowe statystyki dla problemów klasyfikacyjnych.

Najlepsza wygenerowana sieć typu MLP (nr 10) wykazała dobre własności klasyfikacyjne (rys. 3 - tabela: „Statystyki dla problemów klasyfikacyjnych”). Na niebiesko zaznaczono wyniki testów, podczas których prezentowano wygenerowanej



Rys. 2. Proces tworzenia zbioru uczącego
Fig. 2. Process of creating learning file

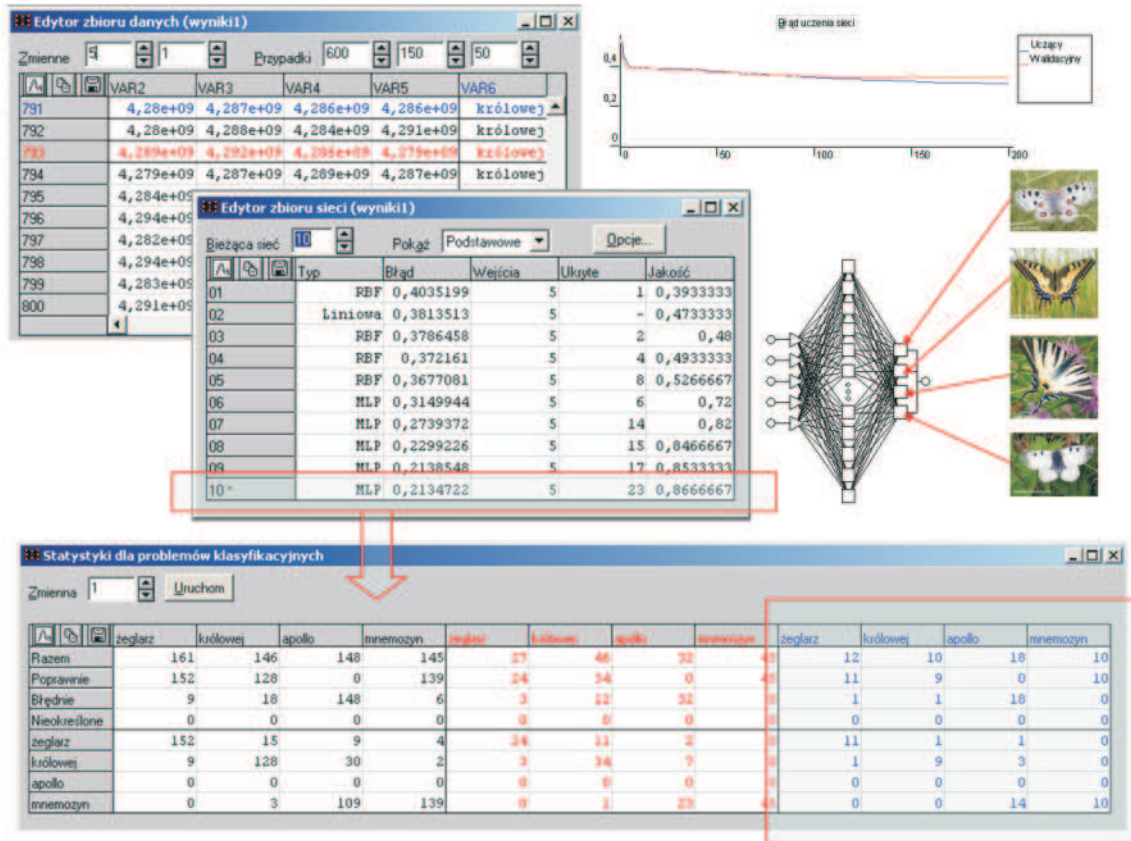
sieci przypadki z jakimi nie miała do czynienia w procesie jej optymalizacji. Jedynie niepylak apollo, którego ubarwienie jest bardzo podobne do niepylaka mnemozyny (rys. 1.) był klasyfikowany błędnie. W tym przypadku klasyfikacja w oparciu o barwę i teksturę, reprezentowaną jedynie przez pięć dominujących kolorów, była trudna do przeprowadzenia.

5. Klasyfikacja „bezwzorcowa”


Identyfikacja informacji zakodowanej w postaci graficznej jest często prowadzona w sytuacji braku pełnej wiedzy, pozwalającej na zakwalifikowanie przynależności obiektów, znajdujących się na obrazie, do określonych klas. W procesie generowania topologii neuronowej często zdarza się, że pełna informacja możliwa do wykorzystania przez algorytm optymalizacyjny, zawarta jest w zbiorze uczącym złożonym z obiektów, dla których prawidłowa klasyfikacja nie jest zdefiniowana. Oznacza to, że w zbiorze uczącym nie jest zawarta jawna postać „odpowiedzi” sieci neuronowej [5]. W takim przypadku rozwiązaniem staje się wykorzystanie topologii opartej na neuronach radialnych, takich jak np. sieci Kohonena typu SOFM (ang. *Self-Organizing Feature Maps*), które można uczyć w oparciu o zredukowany zbiór uczący tzw. techniką „bez nauczyciela”.

Do tworzenia modelu neuronowego typu SOFM użyto zbioru uczącego wykorzystanego do generowania sieci MLP. „Wygaszono” zmienną wyjściową, pozostawiając jedynie przypadki zawierające zmienne wejściowe. Zbudowana sieć neuronowa typu Kohonena składała się z dwóch warstw: wejściowej zawierających pięć neuronów oraz wyjściowej, w postaci mapy topologicznej o wymiarach 12×12. Uczenie sieci z wykorzystaniem algorytmu Kohonena wykonano dwufazowo. W pierwszym etapie, zachodzącym w trakcie tysiąca epok, przyjęto malejący współczynnik uczenia w zakresie od 0.5 do 0.1, zachowując przy tym ustalony rozmiar sąsiedztwa równy 1.

W drugim przebiegu (kolejne tysiąc epok) ustawiono stałą wartość współczynnika uczenia na poziomie 0.1 oraz zastosowano stabilizujący rozmiar sąsiedztwa równy 0. Na rys. 4 pokazano wykres błędów uczenia sieci dla zbioru uczącego (zaznaczony na niebiesko) oraz dla zbioru walidacyjnego (zaznaczony na czerwono). Na rysunku tym przedstawiono również podstawowe statystyki klasyfikacyjne oraz zaetykietowaną mapę topologiczną, będącą graficzną interpretacją działania klasyfikatora neuronowego.



Rys. 3. Proces tworzenie klasyfikatora neuronowego typu MLP
 Fig. 3. Process of creating neural network model type MLP



Rys. 4. Proces tworzenie klasyfikatora neuronowego typu Kohonen
 Fig. 4. Process of creating Kohonen neural network model

Wygenerowana sieć typu SOFM wykazała tendencję do grupowania motyli w dwóch klasach, separowanych na rys. 4 za pomocą niebieskich krzywych: motyle o dominacji koloru białego (niepylak apollo i niepylak mnemozyna) oraz motyle o barwie zróżnicowanej (paź królowej i paź żeglarz). W klasach tych sieć Kohonena potrafiła separować poszczególne gatunki (odróżnia np. niepylaka apollo od niepylaka mnemozyny) jednak, w stosunku do sieci MLP, realizowała znacząco mniej poprawnych klasyfikacji (rys. 4 - tabela: „Statystyki dla problemów klasyfikacyjnych”).

6. Podsumowanie

Z przeprowadzonych badań wynika, że lepszym klasyfikatorem okazała się sieć typu MLP. Uczenie jej, przeprowadzone w oparciu o techniki nadzorowane, odbywało się z wykorzystaniem zbioru zawierającego więcej informacji o klasyfikowanych obiektach (znane były odpowiedzi sieci w postaci nazw motyli). Należy jednak zauważyć, że perceptron miał istotne trudności z klasyfikacją obiektów charakteryzujących się dużym podobieństwem. Sugeruje to celowość zwiększenia liczby reprezentacyjnych cech charakterystycznych w strukturze zbioru uczącego, np. przyjmując jako dodatkowe zmienne wejściowe wybrane współczynniki kształtu. Wytworzona sieć typu MLP dedykowana może być do wykorzystania jako efektywne narzędzie identyfikacyjne.

Sieć typu SOFM wyraźnie gorzej radziła sobie z klasyfikacją poszczególnych odmian motyli skłaniając się przy tym do separacji owadów do dwóch, istotnie różniących się grup. Należy jednak pamiętać, że uczona była ona w oparciu o zredukowany zbiór uczący (bez zmiennych wyjściowych). Potrafiła ona też klasyfikować obiekty do siebie podobne. Sugeruje to celowość dalszej optymalizacji wygenerowanej sieci, np. z użyciem któregoś z algorytmów LVQ.

7. Wnioski

1. Wykazana została celowość zastosowania sieci neuronowych typu MLP oraz typu SOFM do klasyfikacji motyli na podstawie ich obrazów, przeprowadzonej w oparciu o kryterium, jakim jest informacja o barwie oraz teksturze.
2. Sieć typu MLP uczona technikami „z nauczycielem” okazała się lepszym klasyfikatorem w stosunku do sieci typu SOFM uczonej metodą „bez nauczyciela”, w szczególności dla motyli o zróżnicowanym ubarwieniu.
3. Przeprowadzone badania wykazały, że istotny wpływ na jakość identyfikacji motyli ma struktura danych wejściowych, a w szczególności właściwy dobór cech reprezentatywnych, charakteryzujących klasyfikowane motyle.

8. Literatura

- [1] Boniecki P., Piekarska-Boniecka H.: Neuronowa identyfikacja wybranych szkodników drzew owocowych w oparciu o cyfrowe techniki analizy obrazu. *Journal of Research and Applications in Agricultural Engineering*, nr 2, 2004, pp. 19-23.
- [2] Boniecki P.: Elementy modelowania neuronowego w rolnictwie. WUP Poznań 2008.
- [3] Nowakowski K., Boniecki P., Weres J., Mueller W.: Przetwarzanie graficznych danych empirycznych dla potrzeb edukacji sztucznych sieci neuronowych, modelujących wybrane zagadnienia inżynierii rolniczej. *Inżynieria Rolnicza* 2007, 2(90), str. 243-248.
- [4] Ossowski S.: Sieci neuronowe do przetwarzania informacji. Warszawa 2000.
- [5] Tadeusiewicz R.: Rozpoznawanie obrazów. Warszawa 1998.

CLASSIFICATION OF PROTECTED *PAPILIONIDAE* BUTTERFLIES USING SELECTED NEURAL NETWORK TOPOLOGY

Summary

The aim of this study was to compare the classification ability of neural models, learned with two different ways: with reference and without reference. Selected insects subjected to classification belong to the family "Papilionidae", and are a subject to legal protection in Poland. Neural classification was based on the information encoded in the form of a file of two-dimensional images of insects. As representatives of features, which form the basis of the classification, adopted were five dominant butterflies colors. For comparison two neural topologies were generated: a network type MLP (Multilayer Perceptron) learned by method "with the teacher" and a neural network type Kohonen, which was learned by method "without a teacher."