

Możliwości wykorzystania sztucznych sieci neuronowych w klasyfikacji pola wirowości ruchu powietrza nad Europą

1. Wstęp

W badaniach klimatologicznych bardzo często mamy do czynienia z problemem klasyfikacji zjawisk. Opis stanu systemu klimatycznego stał się w obecnej dobie na tyle wszechstronny, iż ilość danych, na podstawie których badacz musi podejmować decyzję o klasyfikacji danego zjawiska jest wprost niewyobrażalna.

Złożoność systemu klimatycznego jest, praktycznie rzecz biorąc, nieskończona, tak jak i ilość zmiennych czy też stopni swobody tegoż systemu. Dlatego też zagadnienie możliwości prognozowania, czy też uporządkowania zjawisk w określone klasy jest szczególnie interesujące. Celem prowadzonych badań było przeprowadzenie klasyfikacji wzorców pola wirowości ruchu powietrza nad obszarem europejsko-atlantyckim z wykorzystaniem sztucznych sieci neuronowych (konkretnie algorytmu Kohonena), jak również przedstawienie potencjalnych problemów i zagadnień dotyczących tej metody.

2. Wprowadzenie do SNN

Sztuczne sieci neuronowe (SSN) należą, wraz z innymi technikami obliczeniowymi, do narzędzi analitycznych klasy AI (Artificial Intelligence – Sztuczna Inteligencja). Mimo, że istnieje, zależnie od przeznaczenia, wiele rodzajów SSN, ogólne zasady działania SSN są, w swym pierwotnym założeniu, zbliżone do sposobu funkcjonowania mózgu ludzkiego. Składają się one z neuronów, w których zachodzi sumowanie iloczynu sygnału wejściowego oraz wartości wag synaptycznych. Wartość ta stanowi następnie informację wejściową funkcji aktywacji neuronu. W sposób znacznie uprosz-

$$y_i = f\left(\sum_{j=1}^n W_{ij} x_j\right)$$

gdzie:

- y_i – sygnał wyjściowy neuronu i
- $f()$ – funkcja aktywacyjna
- x_j ($j=1, 2, \dots, n$) – sygnał elementu wektora wejściowego
- W_{ij} ($j=1, 2, \dots, n$) – współczynniki wagowe (wagi synaptyczne)
- n – liczba elementów wektora wejściowego

czony może to zostać wyrażone następującą formułą matematyczną (Osowski 1996).

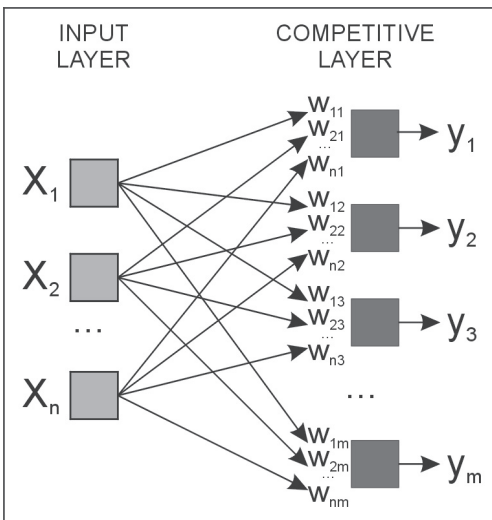
Poprzez wykorzystanie nieliniowych funkcji aktywacji oraz procesu uczenia sieci, który jest podstawowym wyróżnikiem technik AI, SSN pozwalają na analizę skomplikowanych układów wielowymiarowych, wnikanie w zakamuflowane struktury danych oraz ich wzajemne związki. Uczenie neuronu odbywa się poprzez adaptację wag synaptycznych zgodnie z założonym algorytmem uczenia sieci.

3. Metody badań i materiał źródłowy

Zadania klasyfikacji, z wykorzystaniem SSN, można wykonać za pomocą jednego z najczęściej stosowanych algorytmów, a mianowicie z wykorzystaniem uczenia konkurencyjnego algorytmem Kohonena (Tadeusiewicz 1993, 1998).

W przeciwieństwie do większości algorytmów, które weryfikują dobroć dopasowania (np. błąd średniokwadratowy) względem zbioru testującego, zastosowany algorytm bazuje na samouczeniu (*unsupervised learning*). Mapa Kohonena jest specyficzną klasą SSN, jako że posiada ona zdolność tworzenia zachowujących topologię odwzorowań układów wielowymiarowych (Zell i in. 1995). Sieć Kohonena składa się z dwóch warstw (ryc. 1): wejściowej (*input layer*), gdzie wartości aktywacji neuronów są tożsame z kolejnymi wartościami elementów wektora wejściowego (w przypadku prowadzonych badań, była to jednorazowa realizacja pola wirowości - 171 elementów) oraz warstwy, w której zachodzi konkurencja między neuronami (*competitive layer*). Każdy neuron w warstwie współzawodniczącej (*competitive layer*) jest charakteryzowany przez wektor wag synaptycznych:

$$\langle w_{1m}, w_{2m}, w_{3m}, \dots, w_{nm} \rangle$$



gdzie:

n – numer neuronu wejściowego
 m – numer neuronu w warstwie konkurencyjnej, którego „rozmiar” dla każdego neuronu równy jest liczbie elementów w warstwie wejściowej.

Przed rozpoczęciem procesu uczenia niezbędna jest inicjalizacja w warstwie konkurencyjnej znormalizowanymi wektorami wag. Następnie, poddane wcześniej normalizacji wektory wejściowe:

$$\langle x_1, x_2, \dots, x_n \rangle$$

gdzie:

x_i ($i=1,2,\dots,n$) – elementy wektora wejściowego (tożsame z wartościami aktywacji neuronów w warstwie

Ryc. 1. Model sieci Kohonena (Marosz, 2000) (wejściowej)

są prezentowane wszystkim neuronom współzawodniczącym, a najbardziej podobny do wektora wejściowego jest neuronem zwycięzcą, przy czym miara podobieństwa, w przypadku normalizacji wektorów (wejściowego i wag), wyraża się jako (Zell i in. 1995):

$$y_m = X \cdot W_m = \sum_{i=1}^n x_i w_{im}$$

gdzie:

y_m – sygnał wyjściowy neuronu m

X – wektor wejściowy

W_m – wektor wag synaptycznych neuronu m

w_{im} ($i= 1,2,\dots,n$) wagi synaptyczne neuronu m

x_i ($i= 1,2,\dots,n$) składowe wektora wejściowego

n – liczba elementów wektora wejściowego

Neuronem najbardziej podobnym do wektora wejściowego jest ten, dla którego wartość y_m jest największa. Następnie w procesie uczenia, przeprowadzonego zgodnie z regułą: zwycięzca bierze wszystko (*WTA Rule – Winner Takes All*), uczestniczy jedynie neuron zwycięzca i tylko jego wagi są adaptowane, tak iż stopień podobieństwa będzie większy, kiedy ten sam wektor wejściowy zostanie ponownie zaprezentowany w kolejnej epoce uczenia. Algorytm uczenia sieci może być wyrażony następująco (Osowski 1996):

$$W_{i(k+1)} = W_{i(k)} + \eta_{i(k)} [X - W_{i(k)}]$$

gdzie:

$h_{i(k)}$ – współczynnik uczenia i -tego neuronu w k -tej iteracji

$W_{i(k)}$ – wektor wag synaptycznych i -tego neuronu w k -tej iteracji

X – wektor wejściowy

Wyrażony powyżej, za pomocą formuły matematycznej, iteracyjny proces uczenia można obrazowo opisać w następujący sposób. Każdy ze znormalizowanych wektorów wejściowych, jak również każdy neuron w warstwie konkurencyjnej, identyfikowany jest jako punkt w n -wymiarowej przestrzeni, gdzie n jest liczbą neuronów w warstwie wejściowej, tożsamą z liczbą elementów wektora wejściowego jak również wektora wag. Proces uczenia (pojedyncza iteracja) opiera się na dwóch krokach: w pierwszym następuje wyłonienie neuronu zwycięskiego, w następnym zaś adaptacja jego wag, zgodnie z powyższą formułą, powodującą zbliżenie do siebie obu punktów w n -wymiarowej przestrzeni. Po zaprezentowaniu całego zbioru wektorów wejściowych (1 epoka), kolejność prezentacji wektorów jest losowo modyfikowana i następuje kolejna epoka uczenia. Ukończenie procesu uczenia sieci oznacza, iż dla zbioru wektorów wejściowych najbardziej do siebie podobnych, zwycięzcą będzie ten sam neuron (Marosz 2001).

Strategia uczenia w przypadku zadania mającego na celu wyróżnienie (a następnie zaklasyfikowanie do nich poszczególnych realizacji pola wirowości) typów, zakłada arbitralny dobór liczby neuronów w warstwie konkurencyjnej. Teoretycznie sieć może mieć bardzo dużą (maksymalnie jest to liczebność wektorów uczących) liczbę neuronów w warstwie konkurencyjnej, aczkolwiek możliwe jest (Marosz 2001), że przy dość dużym zróżnicowaniu pól elementów meteorologicznych można spodziewać się sytuacji, iż większość neuronów będzie podlegać uczeniu (nie zaistnieje sytuacja, w której pozostaną „na placu boju” neurony martwe – które nigdy nie podlegały uczeniu). Wówczas przy dużej liczbie neuronów, a co za tym idzie typów, analiza informacji fizycznej jaką niosą ze sobą poszczególne typy stanie się kłopotliwa, jeśli nie niemożliwa. Z drugiej jednak strony, przyjmując za fakt „naturalne” zdolności algorytmu Kohonena do generalizacji informacji, można spodziewać się, iż niektóre neurony nie będą podlegały uczeniu a sieć automatycznie dokona wyróżnienia odpowiedniej liczby wzorców.

Mając na celu, obok podstawowego zagadnienia jakim była sama klasyfikacja, przedstawienie wpływu stopnia generalizacji (reprezentowanego przez liczbę neuronów w warstwie konkurencyjnej) zdecydowano się na porównanie wyników procedury klasyfikacyjnej w dwóch wersjach. W pierwszej zastosowano stosunkowo niewielką (5) liczbę neuronów w warstwie konkurencyjnej, w drugiej zaś przeprowadzono tą samą procedurę dla 15 neuronów.

Podstawowym materiałem źródłowym, który wykorzystano w badaniach była reanaliza NCEP/NCAR (Kalnay i in. 1996) z lat 1981-90. Posłużono się przy tym wersją z rozdzielczością przestrzenną 2,5x2,5 stopnia o kroku czasowym 6h. W toku prac obliczono średnie dobowe wartości wirowości względnej ruchu powietrza w siatce o rozdzielczości przestrzennej 5x5 stopni. Wirowość względna ruchu powietrza jest obiektywną miarą charakteru ruchu powietrza i można wyrazić ją w postaci następującego wzoru (Zwieriew

$$\Omega = \frac{\partial v}{\partial x} - \frac{\partial u}{\partial y}$$

gdzie:


Ω – wirowość względna

u, v – składowe wektora prędkości wiatru


x, y – współrzędne układu odniesienia (oś y jest skierowana na północ; x na wschód)

Pozwala ona stwierdzić, czy przepływ powietrza cechuje się cyklonalnym (dodatnie wartości) czy antycyklonalnym (ujemne wartości) zakrzywieniem linii prądu, co w przypadku umiarkowanych szerokości geograficznych, w których cyrkulacja atmosferyczna jest głównym czynnikiem pogodowym i jej główną cechą jest przemieszczanie się z zachodu na wschód układów barycznych ma szczególne znaczenie. W obliczeniach wykorzystano składowe wektora wiatru na powierzchni izobarycznej 700 hPa. Posłużono się również integralnymi funkcjami programu GrADS, służącego do wizualizacji oraz obliczeń na danych


gridowych, pozwalającymi na obliczenie wartości wirowości ruchu powietrza z wykorzystaniem metody różnic skończonych. Utworzono następnie bazę danych zawierających wartości wirowości ze 171 punktów obejmujących obszar 40W-50E



Ryc. 2. Wzorce pola wirowości na 700 hPa (wariant - 5 neuronów) po 100 oraz 500 epokach uczenia (1981-90)



Ryc. 3. Wzorce pola wirowości na 700 hPa (wariant - 15 neuronów) po 100 epokach uczenia (1981-90), obszar badań (w środku na dole strony)

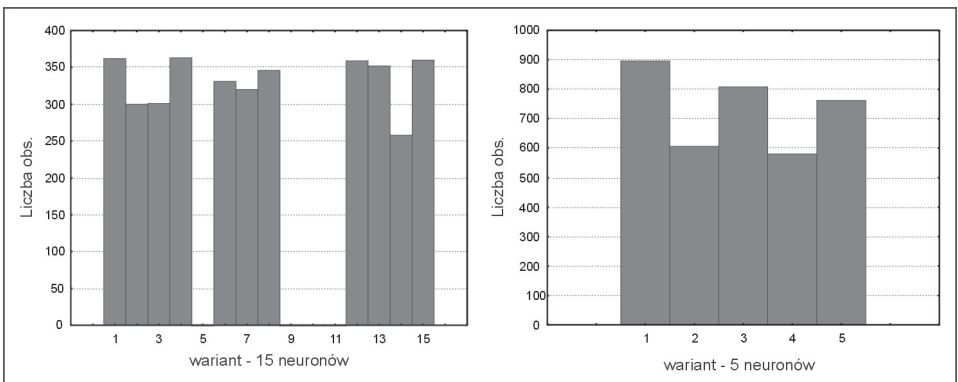


Ryc. 4. Wzorce pola wirowości na 700 hPa (wariant - 15 neuronów) po 500 epokach uczenia sieci (1981-90), obszar badań (w środku na dole strony)

oraz 35N-75N. Po standaryzacji wektorów wejścia, czyli kolejnych realizacji pola wirowości, wykorzystano pakiet SNNS 4.2 (Stuttgart Neural Network Simulator) w celu zaimplementowania procedur związanych z algorytmem Kohonena.

4. Wyniki

Ryciny 2-4 przedstawiają wzorce pola wirowości po odpowiednio 100 oraz 500 epokach uczenia sieci (odpowiednio: 365 200 oraz 1 826 000 iteracji). Rycina 2 przedstawia wyniki procesu uczenia sieci Kohonena dla pięciu neuronów natomiast ryciny 3 oraz 4 przedstawiają przestrzenny rozkład wag sieci Kohonena dla jedenastu neuronów. Należy zwrócić uwagę na kilka charakterystycznych cech. Po pierwsze w kolejnych krokach uczenia następuje coraz lepsze dopasowanie wartości wag, czego skutkiem jest „wygładzony” obraz na rycinach przedstawiających wyniki dla 500 epok. Kolejnym faktem zwracającym uwagę jest sytuacja w wariacie z 15 neuronami, w którym nie wszystkie neurony podlegały adaptacji (wagi czterech neuronów nie zmieniły się). Można zaryzykować stwierdzenie, że SIEĆ dokonała generalizacji wzorców i wydzieliła jedynie tyle, ile było niezbędne zważając na strukturę danych wejściowych. Świadczy to o tym, iż liczba wzorców na poziomie 15 jest zbyt duża. Mapy wzorców prezentują zróżnicowane położenie ośrodków cyklonalnego i antycyklonalnego ruchu powietrza nad obszarem badań. Zważywszy na skalę czasową obliczeń, można stwierdzić, że są to średnie dobowe wzorce pola wirowości względnej. Można również zauważyć, iż wariant z 5 neuronami znacznie generalizuje pole wirowości względnej wskazując jedynie dominujące cechy przepływu powietrza nad Europą na wysokości 700 hPa, zazwyczaj z jednym lub dwoma centrami aktywności na Północnym Atlantyku. Widać również znaczną adaptację wartości wag neuronów jaka nastąpiła po 400 dodatkowych epokach uczenia. Wariant z 15 neuronami ujawnia o wiele większe zróżnicowanie pola wirowości. Należy podkreślić, iż jedynie 11 neuronów podlegało adaptacji. Pozostałe nie brały udziału w procesie uczenia. Klasyfikacja z 15 neuronami pozwoliła na bardziej szczegółowe rozpoznanie




Ryc. 5. Liczebność poszczególnych wzorców pola wirowości względnej (1981-90)


charakterystycznych dla obszaru badań form cyrkulacji i obok wzorców zbliżonych to tych z klasyfikacji z 5 neuronami otrzymano warianty wzorców średniego dobowego pola wirowości względnej, wyraźnie uszczegóławiające ogólny obraz, reprezentowany przez wzorce z klasyfikacji z 5 neuronami.

Na kolejnych rycinach (5, 6 i 7) przedstawiono liczebność wystąpień wyróżnionych wzorców pola wirowości względnej oraz sezonowe zróżnicowanie ich występowania. Niewątpliwie zaznacza się zróżnicowanie sezonowe przy czym wyraźniej widać je w przypadku klasyfikacji z 15 neuronami.

W przypadku klasyfikacji z 5 neuronami w skali roku dominują wzorce 1, 3 oraz 5, z których pierwsze dwa charakteryzują się znacznym rozbudowaniem obszaru cyklonalnego przepływu powietrza, który można utożsamiać z Niżem Islandzkim i wyraźnie zaznaczonym obszarem antycyklonalnego charakteru przepływu w rejonie Wyżu Azorskiego (znacznie przesuniętego ku północnemu wschodowi i bardziej rozbudowanego w przypadku wzorca 2). Dla wzorca 5 charakterystyczne jest przesunięcie obszaru ujemnych wartości wirowości względnej na północ i znaczne ograniczenie jego zasięgu. W tym wariantcie klasyfikacji zróżnicowanie sezonowe nie ujawnia się zbyt mocno z wyjątkiem sezonu zimowego, kiedy to zaznacza się wyraźna dominacja wzorca 1. Okres wiosenny charakteryzuje się niemal jednakowym udziałem poszczególnych wzorców. Natomiast w lecie zaznacza się jedynie niemal trzykrotne,



Ryc. 6. Sezonowe zróżnicowanie częstości występowania wzorców wirowości w wariantcie z 15 neuronami (1981-90)



Ryc. 7. Sezonowe zróżnicowanie częstości występowania wzorców pola wirowości względnej w wariancie z 5 neuronami (1981-90)

w stosunku do liczebności innych wzorców, zmniejszenie częstości występowania wzorca 4.

W przypadku klasyfikacji z 15 neuronami w skali roku zaznacza się jedynie nieznaczne zróżnicowanie przy czym wzorce dominujące (1, 4, 12, 13, 15) można, stosując znaczne uproszczenie, zaliczyć do charakterystycznego dla obszaru atlantycko-europejskiego sposobu przepływu powietrza – z zachodu na wschód. Znacznie wyraźniejsze niż miało to miejsce w przypadku klasyfikacji z mniejszą ilością neuronów jest w tym przypadku zróżnicowanie sezonowe. W każdym z sezonów można wyróżnić wzorce dominujące (zazwyczaj trzy) i jedynie w przypadku dwóch z nich występują one w różnych porach roku (wzorec 1: zima, wiosna; wzorec 15: jesień, zima).

5. Podsumowanie

Generalnie, należy stwierdzić, iż zastosowana metoda pozwoliła na wyróżnienie wzorców pola wirowości względnej nad obszarem badań. Stosunkowo prosta implementacja, łatwość interpretacji wyników i dostępność darmowych narzędzi, które z powodzeniem mogą zastąpić komercyjne pakiety, czynią z niej atrakcyjną alternatywę badawczą. Możliwość późniejszej analizy wyników w postaci map wag neuronowych,

które mogą być utożsamiane z przeciętnymi znormalizowanymi wartościami wskaźnika w każdym z punktów, oraz jednoznacznego zaklasyfikowania każdego z dni do konkretnego wzorca na podstawie obiektywnej miary podobieństwa pozwala na pogłębioną analizę charakterystyki cyrkulacji atmosferycznej nad obszarem badań.

Literatura

- Kalnay E., Kanamitsu M., Kistler R., Collins W., Deaven D., Gandin L., Iredell M., Saha S., White G., Woollen J., Zhu Y., Leetmaa A., Reynolds B., Chelliah M., Ebisuzaki W., Higgins W., Janowiak J., Mo K.C., Ropelewski C., Wang J., Jenne R. J. D., 1996, *The NCEP/NCAR 40-Year Reanalysis Project*, Bull. Amer. Meteor. Soc., 77, 437-472.
- Marosz M., 2001, *Zastosowanie sztucznych sieci neuronowych w obiektywnej klasyfikacji wzorców średniego dobowego pola ciśnienia*, Przegł. Fiz.-Geogr., VI, Wyd. UG, Gdańsk.
- Osowski S., 1996, *Sieci neuronowe w ujęciu algorytmicznym*, WNT, Warszawa.
- Tadeusiewicz R., 1993, *Sieci Neuronowe*, Akademicka Oficyna Wydawnicza, Warszawa.
- Tadeusiewicz R., 1998, *Sieci neuronowe - chwilowa fascynacja? [w:] Zastosowanie sztucznych sieci neuronowych w hydrologii*, Kraków, 3-27.
- Stuttgart Neural Network Simulator. User Manual, Version 4.1, 1995, University of Stuttgart, Institute for Parallel and Distributed High Performance Systems, adres internetowy: <http://www-ra.informatik.uni-tuebingen.de/SNNS/>, data pobrania: 14.06.2004.*
- Zwieriew N. I., 1965, *Meteorologia synoptyczna*, WKiŁ, Warszawa.

Michał Marosz
Katedra Meteorologii i Klimatologii
Uniwersytet Gdański
Gdańsk

