

OCENA MOŻLIWOŚCI STOSOWANIA SZTUCZNYCH SIECI  
NEURONOWYCH DLA OKREŚLANIA ŚREDNIEJ ROCZNEJ WARTOŚCI  
WSKAŹNIKA EROZYJNOŚCI DESZCZY\*

*Paweł Licznar*

Instytut Budownictwa i Architektury Krajobrazu, Akademia Rolnicza  
Pl. Gruwaldzki 24, 50-363 Wrocław  
e-mail: licznarp@ozi.ar.wroc.pl

**Streszczenie.** Jednym z najsłabiej rozpoznanych parametrów Uniwersalnego Równania Strat Glebowych USLE w Polsce jest wskaźnik erozyjności deszczy. Celem badań była ocena możliwości stosowania sztucznych sieci neuronowych dla określania średniej rocznej wartości wskaźnika erozyjności deszczy na podstawie znajomości jedynie średnich miesięcznych sum opadów. W badaniach oparto się na bazie danych z 90 stacji opadowych z obszaru Polski i Niemiec. W ramach przeprowadzonej oceny przeanalizowano możliwości stosowania dla założonego celu sieci typu perceptronowego o pojedynczej i podwójnej warstwie ukrytej oraz sieci o radialnych funkcjach bazowych. Wykazano, że satysfakcjonujące wyniki predykcji średnich rocznych wartości wskaźnika erozyjności deszczy są możliwe do otrzymania na podstawie średnich miesięcznych sum opadów przy wykorzystaniu sieci perceptronowych, posiadających jedną lub dwie warstwy ukryte oraz sieci o radialnych funkcjach bazowych. Jednocześnie badania wykazały brak możliwości stosowania metody zmodyfikowanego indeksu Fourniera dla tego celu.

**Słowa kluczowe:** wskaźnik erozyjności deszczy, sztuczne sieci neuronowe, zmodyfikowany indeks Fourniera

WSTĘP

Jednym z najsłabiej rozpoznanych parametrów Uniwersalnego Równania Strat Glebowych USLE w Polsce jest wskaźnik erozyjności deszczy. W przeciwieństwie do wielu państw europejskich, w tym także sąsiedzkich takich jak: Niemcy, Czechy, Słowacja, w Polsce jak dotąd wartości wskaźnika w oparciu

---

\*Praca wykonana w ramach projektu badawczego Nr: 5 P06 3 023 24 finansowanego przez Komitet Badań Naukowych w latach 2003-2005.

o dane pluwiograficzne zostały obliczone jedynie dla około 10 stacji meteorologicznych. Charakter kompleksowy posiada jedynie mapa przestrzennego zróżnicowania wskaźnika erozyjności opadów w Polsce, oparta na analizie zmodyfikowanego indeksu Fourniera autorstwa H. Lorenc, dostępna dla szerszego grona odbiorców w monografii A. i C. Józefaciuków [7].

Obliczenie wartości wskaźnika erozyjności deszczy dla wielu obszarów kraju napotyka na liczne przeszkody, którymi jest choćby brak dostępu do wieloletnich zapisów pluwiograficznych i pracochłonność ich przetwarzania. Z drugiej strony istnieje dosyć duża dostępność do danych o miesięcznych sumach opadów. Są one zbierane w Polsce, nie tylko na sieci stacji meteorologicznych, ale na znacznie gęstszej sieci posterunków opadowych.

Ogólne rozpoznanie kształtowania się wartości wskaźnika erozyjności deszczy może być realizowane dzięki jego przybliżonemu szacowaniu na podstawie bardziej uogólnionych i łatwiej dostępnych danych opadowych. Na przykład FAO, w tym zakresie, zaleca stosowanie wskaźnika Fourniera, obliczanego z miesięcznych sum opadów [8]. Analizę możliwości stosowania zmodyfikowanego indeksu Fourniera w warunkach USA przeprowadzili Renard i Freimund [12], a w zachodniej części Europy był on stosowany przez Gabrielsa [4]. Ponadto Sauerborn i in. [14] stosowali go dla identyfikacji wartości wskaźnika  $R_r$  przy założonych scenariuszach zmian klimatycznych. Innym rozwiązaniem dyskusyjnego problemu jest algorytm de Santos Loureiro i de Azevedo Coutinho [3], estymacji wskaźnika  $R_r$ , bazujący jedynie na sumach dobowych opadów, przekraczających 10 mm. Metodyka ta była praktycznie przetestowana dla regionu Algarve w Portugalii. Jej uwieńczeniem było opracowanie mapy wskaźnika erozyjności deszczy dla tego rejonu z wykorzystaniem metody krigingu, dającej wyniki znacznie bardziej wiarygodne od prostych metod interpolacyjnych [5]. Z uwagi na coraz szerszy zakres stosowania sztucznych sieci neuronowych, w tym zwłaszcza dla przetwarzania danych meteorologicznych [9] i modelowania procesów erozji wodnej gleb [10] wydaje się, że powinna zostać także rozpoznana możliwość ich użycia dla określania wartości wskaźnika erozyjności deszczy, w oparciu o uogólnione dane opadowe.

Celem podjętych badań była ocena możliwości stosowania sztucznych sieci neuronowych dla określania średniej rocznej wartości wskaźnika erozyjności deszczy na podstawie znanych średnich miesięcznych sum opadów. Ocena ta miała polegać na przeanalizowaniu możliwości stosowania sieci różnego typu i o różnej architekturze, dla predykcji wartości średnich rocznych wskaźnika  $R_r$  w oparciu o jedynie średnie miesięczne sumy opadów z wielolecia. Dodatkowym celem badań była ocena możliwości stosowania, w tym zakresie, również klasycznej metody zmodyfikowanego indeksu Fourniera.

## MATERIAŁ I METODY

Do badań wykorzystano bazę danych zawierającą średnie roczne wartości wskaźnika erozyjności deszczy oraz odpowiadające im średnie miesięczne sumy opadów z łącznej liczby 90 stacji meteorologicznych. Większość danych pochodziła ze stacji położonych w Niemczech. Materiał ten uznano za właściwy, przede wszystkim z uwagi na fakt, że stosowana w Niemczech metodyka obliczania wartości wskaźnika  $R_r$  w oparciu o zapisy pluwiograficzne jest metodą klasyczną zaproponowaną przez Wischmeiera i Smitha [16], przyjętą także za standardową w Polsce [1,2,6]. W fazie wstępnej pracy odrzucono natomiast koncepcję rozszerzenia bazy danych o wartości wskaźnika erozyjności deszczy z obszaru Czech i Słowacji, gdyż z uwagi na inne przyjęcie definicji deszczy erozyjnych przez badaczy z tych państw, wyniki ich prac są znacząco odmienne od opublikowanych rezultatów prac polskich i niemieckich. Najlepszym przykładem obrazującym wspomniane rozbieżności jest porównanie map izoerodentów (ang. isoerodents) wykonanych przez Suerborn [13] dla Niemiec oraz przez Švehlę i Skořepa [15] dla Czech. Na granicy obydwu państw można zauważyć, że badacze czescy zaniżają wartości wskaźnika erozyjności deszczy o około jeden rząd wielkości.

Dane z obszaru Niemiec zostały uznane za właściwe także z uwagi na bliskość tego obszaru i podobieństwo warunków klimatycznych, zwłaszcza opadowych, do spotykanych na terenie naszego kraju. Wydaje się, że podobieństwo to pozwala na opracowanie techniki przybliżonego szacowania wartości wskaźnika  $R_r$  na podstawie miesięcznych sum opadów, w oparciu o dane niemieckie, a następnie jej zastosowanie w warunkach krajowych. Jest to szczególnie potrzebne dla zachodnich obszarów Polski, dla których prawie zupełnie brak jest rozpoznania kształtowania się wartości wskaźnika erozyjności deszczy.

Baza danych z obszaru Niemiec została uzupełniona o średnie roczne wartości wskaźnika erozyjności deszczy i odpowiadające im średnie miesięczne sumy opadów dla czterech stacji w Polsce. Stacjami tymi były: Puławy, Sandomierz, Limanowa oraz Wrocław-Swojec. Wartości erozyjności deszczy dla tych stacji zostały wyznaczone zgodnie z oryginalną metodyką USLE, w oparciu o zapisy pluwiograficzne i były już wcześniej publikowane [1,2,6,8,11]. W obrębie całego zbioru danych najwyższą wartość wskaźnika  $R_r$ , równą  $159,9 \text{ MJ}\cdot\text{ha}^{-1}\cdot\text{cm}\cdot\text{h}^{-1}$ , zanotowano dla położonej w górach Schwarzwald stacji Freudenstadt, o średniej rocznej sumie 1586 mm opadów. Natomiast najmniejszą średnią roczną wartość wskaźnika  $R_r$  stwierdzono dla stacji Elsdorf ( $21,9 \text{ MJ}\cdot\text{ha}^{-1}\cdot\text{cm}\cdot\text{h}^{-1}$ ) o średniej rocznej sumie opadów wynoszącej jedynie 481 mm. Szczegółową charakterystykę, użytych w badaniach wartości wskaźnika erozyjności deszczy, można znaleźć w pracy Sauerborn [13], gdyż były one w znacznej mierze podstawą dla opracowania mapy izoerodentów dla Niemiec.

Badania przeprowadzono w dwóch etapach. W ramach pierwszego etapu, dla wszystkich 90 stacji, obliczono na podstawie średnich miesięcznych sum opadów wartości zmodyfikowanego wskaźnika Fourniera i porównano je z rzeczywistymi średnimi rocznymi wartościami wskaźnika  $R_r$ .

W drugim etapie badań opracowano sztuczne sieci neuronowe służące predykcji średniej rocznej wartości wskaźnika erozyjności na bazie wartości średnich miesięcznych sum opadów. Sieci neuronowe zostały opracowane przy wykorzystaniu pakietu Sieci Neuronowe 6PL programu STATISTICA. W celu identyfikacji najlepszych sieci, zapewniających otrzymywanie precyzyjnych prognoz średnich rocznych wartości wskaźnika  $R_r$ , zbudowano i przeanalizowano działanie 100 różnych sieci. W obrębie analizowanych sieci znalazły się perceptrony o jednej lub dwóch warstwach ukrytych, z liczbą neuronów na każdej z nich w zakresie od 1 do 13 oraz sieci o radialnych funkcjach bazowych o liczbie neuronów w warstwie ukrytej w zakresie od 1 do 23.


Dla wszystkich sieci liczba neuronów w warstwie wejściowej wynosiła 12 i była zdeterminowana przez liczbę zmiennych wejściowych, którymi były średnie sumy opadów miesięcznych wyrażone w mm. W ostatniej warstwie sieci znajdował się jeden neuron, ponieważ na wyjściu sieci miano otrzymywać, wyrażone w  $MJ \cdot ha^{-1} \cdot cm \cdot h^{-1}$ , wartości średnie roczne wskaźnika erozyjności deszczy.

Przed rozpoczęciem procesu uczenia sieci, cała baza danych, zarówno wartości średnie roczne wskaźnika erozyjności deszczy jak i odpowiadające im średnie miesięczne sumy opadów, zostały w sposób losowy podzielone na trzy podzbiory. Liczebność poszczególnych podzbiorów: uczącego, walidacyjnego i testowego wynosiła odpowiednio 45, 23 i 22 przypadki. Proces uczenia sieci perceptronowych składał się z dwóch etapów. W pierwszym etapie (dla pierwszych 100 cykli uczenia) zastosowano uczenie wsteczną propagacją, z umiarkowaną szybkością uczenia, otrzymując ogólną zbieżność. Podczas drugiego etapu (dla cykli od 101 do końca uczenia) uruchomiono metodę gradientów sprzężonych (algorytm znacznie szybszy obliczeniowo), który po wstępnej fazie wolniejszej wstecznej propagacji nie był już narażony na problemy ze zbieżnością. Dla sieci o radialnych funkcjach bazowych zastosowano algorytmy uczące określające odchylenie radialne ( $K$ -średnich oraz  $K$ -najbliższych sąsiadów) oraz pseudoinwersji (najmniejszych kwadratów). Prezentowane na wejściu sieci dane oraz otrzymywane na wyjściu sieci zbiory wynikowe były poddawane konwersji minimax – skalowaniu liniowemu, służącemu lepszemu funkcjonowaniu sieci.

## WYNIKI I DYSKUSJA

Obliczone na wstępie na podstawie średnich miesięcznych sum opadów wartości zmodyfikowanego wskaźnika Fourniera ( $F$ ), odbiegały znacząco od rzeczy-


wistych średnich rocznych wartości wskaźnika  $R_r$ . Jest to bardzo dobrze widoczne na rysunku 1, na którym wartości zmodyfikowanego wskaźnika Fourniera różnią się od rzeczywistych średniorocznych wartości wskaźnika  $R_r$  w całym zakresie jego zmienności. Potwierdza to także bardzo odległy od nachylenia 1:1 przebieg liniowego związku  $F$  i wskaźnika  $R_r$  oraz bardzo niska wartość współczynnika korelacji dla tego związku, wynosząca jedynie  $r = 0,42$ .



**Rys. 1.** Zależność średniej rocznej wartości wskaźnika  $R_r$  i zmodyfikowanego indeksu Fourniera  
**Fig. 1.**  $R_r$  – factor average annual value versus modified Fournier index relation

Wyniki otrzymane w tym etapie badań pozostają w całkowitej zgodności z uprzednimi badaniami Gabrielsa [4] przeprowadzonymi na podstawie znacznie bogatszej bazy danych obejmującej 2083 stacji meteorologicznych z 16 państw Europy. Stwierdził on słabą przydatność bezpośredniego stosowania zmodyfikowanego indeksu Fourniera dla szacowania wartości średniej rocznej wskaźnika  $R_r$ , zwłaszcza gdy jego wartość była określana od razu na podstawie średnich sum opadów z wielolecia. Postulował on, aby wartości indeksu  $F$  obliczać dla danych z poszczególnych lat w analizowanym wieloleciu, a wartość średnią roczną wskaźnika  $R_r$  przyjmować dopiero jako uśrednioną wartość z otrzymanych indeksów dla analizowanych lat. Jednocześnie Gabriels [4] wskazywał na dodatkową potrzebę opracowania regionalnych zależności statystycznych łączących wartości zmodyfikowanego indeksu Fourniera i wskaźnika  $R_r$ .

Wynikiem drugiej fazy badań był wybór trzech najlepiej funkcjonujących sztucznych sieci neuronowych, służących predykcji średnich rocznych wartości wskaźnika erozyjności deszczy w oparciu o średnie miesięczne sumy opadów. Były to dwie sieci perceptronowe o pojedynczej i podwójnej warstwie ukrytej oraz sieć o radialnych funkcjach bazowych, których architektura jest schematycznie przedstawiona na rys. 2 oraz scharakteryzowana w tabeli 1.



**Rys. 2.** Schematy opracowanych sztucznych sieci neuronowych: a) sieć 1 – MLP 12:12-13-13-1:1, b) sieć 2 – MLP 12:12-13-1:1, c) sieć 3 – RBF 12:12-16-1:1

**Fig. 2.** Diagrams of developed neural networks: a) net 1 – MLP 12:12-13-13-1:1, b) net 2 – MLP 12:12-13-1:1, c) net 3 – RBF 12:12-16-1:1

**Tabela 1.** Podstawowe charakterystyki opracowanych sztucznych sieci neuronowych

**Table 1.** Basic characteristics of developed artificial neural networks architecture

| Sieć – Net             | Warstwa<br>Layer                    | Liczba neuronów<br>Number of neurons | Użyta funkcja aktywacji<br>Activation functions used |
|------------------------|-------------------------------------|--------------------------------------|--|
| 1) MLP 12:12-13-13-1:1 | Wejściowa Input                     | 12                                   | Liniowa – linear                                     |
|                        | Pierwsza ukryta<br>The first hidden | 12                                   | hiperboliczna – hyperbolic                           |
|                        | Druga ukryta<br>The second hidden   | 13                                   | hiperboliczna – hyperbolic                           |
|                        | Wyjściowa Output                    | 1                                    | Logistyczna – logistic                               |
| 2) MLP 12:12-13-1:1    | Wejściowa Input                     | 12                                   | Liniowa – linear                                     |
|                        | Ukryta Hidden                       | 13                                   | hiperboliczna – hyperbolic                           |
|                        | Wyjściowa Output                    | 1                                    | logistyczna – logistic                               |
| 3) RBF 12:12-16-1:1    | Wejściowa Input                     | 12                                   | Liniowa – linear                                     |
|                        | Ukryta Hidden                       | 16                                   | Wykładnicza – exponential                            |
|                        | Wyjściowa Output                    | 1                                    | liniowa – linear                                     |

Proces uczenia sieci perceptronowych miał bardzo podobną długość i trwał w przypadku sieci 1 i 2 odpowiednio 110 i 109 cykli. We wszystkich sieciach funkcją agregującą dla neuronów była funkcja liniowa. Jedynie w przypadku neuronów warstwy ukrytej sieci o radialnych funkcjach bazowych (sieć 3), jako funkcja agregująca, zastosowana była funkcja radialna.

W tabeli 2 zestawiono szczegółowe statystyki regresji rzeczywistych i prognozowanych przez opracowane sieci wartości wskaźnika  $R_r$ , osobno dla podzbiorów: uczącego, walidacyjnego, testowego oraz zbiorcze dla całego zakresu danych.

**Tabela 2.** Statystyki regresji rzeczywistych i prognozowanych wartości wskaźnika  $R_r$  dla analizowanych sieci i zbiorów danych

**Table 2.** Regression statistics of real versus predicted  $R_r$  factor values for analyzed networks and datasets

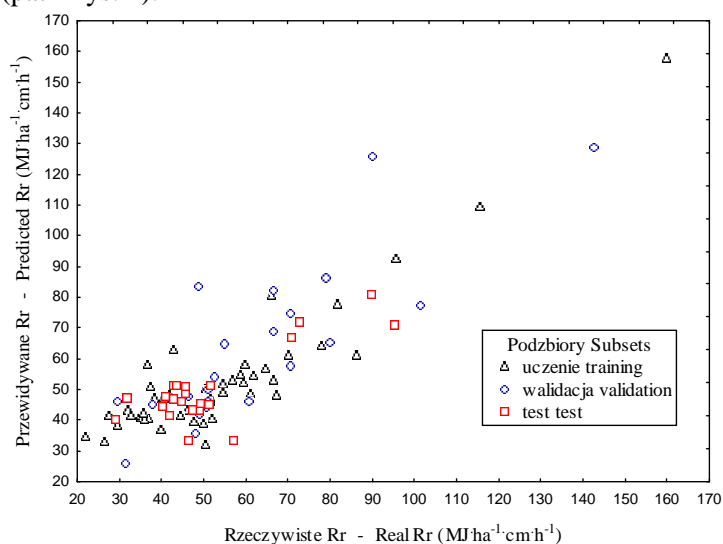
| Podzbiór danych<br>Data subset | Średnia<br>Data Mean | Odch. std.<br>Data S.D. | Średni błąd<br>Mean error | Odch. błędu<br>Abs. E. Mean | Śr. bł. bezwz.<br>T. error S.D. | Iloraz odch.<br>S.D. Ratio | Korelacja<br>Correlation |
|--------------------------------|----------------------|-------------------------|---------------------------|-----------------------------|---------------------------------|----------------------------|--------------------------|
| Sieć 1 – Net 1                 |                      |                         |                           |                             |                                 |                            |                          |
| Uczenie<br>Training            | 54,10                | 24,50                   | -0,71                     | 10,31                       | 8,64                            | 0,42                       | 0,91                     |
| Walidacja<br>Validation        | 62,70                | 24,77                   | 0,86                      | 14,88                       | 11,53                           | 0,60                       | 0,83                     |
| Test<br>Test                   | 51,33                | 16,32                   | -1,19                     | 9,81                        | 7,42                            | 0,60                       | 0,80                     |
| Wszystkie<br>All               | 55,53                | 23,23                   | -0,44                     | 11,51                       | 9,05                            | 0,50                       | 0,87                     |
| Sieć 2 – Net 2                 |                      |                         |                           |                             |                                 |                            |                          |
| Uczenie<br>Training            | 54,10                | 24,50                   | -0,42                     | 13,93                       | 11,40                           | 0,57                       | 0,84                     |
| Walidacja<br>Validation        | 62,70                | 24,77                   | 1,90                      | 13,97                       | 10,73                           | 0,56                       | 0,83                     |
| Test<br>Test                   | 51,33                | 16,32                   | -0,40                     | 9,49                        | 7,11                            | 0,58                       | 0,83                     |
| Wszystkie<br>All               | 55,53                | 23,23                   | 0,15                      | 13,03                       | 10,19                           | 0,56                       | 0,83                     |
| Sieć 3 – Net 3                 |                      |                         |                           |                             |                                 |                            |                          |
| Uczenie<br>Training            | 54,10                | 24,50                   | 0,00                      | 10,83                       | 7,59                            | 0,44                       | 0,90                     |
| Walidacja<br>Validation        | 62,70                | 24,77                   | 1,19                      | 18,48                       | 14,64                           | 0,75                       | 0,71                     |
| Test<br>Test                   | 51,33                | 16,32                   | 1,58                      | 7,99                        | 6,86                            | 0,49                       | 0,88                     |
| Wszystkie<br>All               | 55,53                | 23,23                   | 0,68                      | 12,63                       | 9,14                            | 0,54                       | 0,84                     |

Dla wszystkich podzbiorów danych i dla wszystkich sieci obserwowano wysokie wartości współczynników korelacji, które były dwukrotnie wyższe, od współczynnika otrzymanego podczas analizy możliwości stosowania zmodyfikowanego indeksu Fourniera. Współczynniki te były najwyższe dla podzbioru uczącego, osiągając wartości w zakresie od 0,84 dla sieci 2 do 0,91 dla sieci 1. W przypadku

sieci 3 współczynnik korelacji wynoszący  $r = 0,90$  dla podzbioru uczącego był ponadto stowarzyszony z zerowym średnim błędem oraz stosunkowo niską wartością ilorazu odchyłeń błędu wynoszącą 0,44. Najniższą wartość współczynnika korelacji, wyjątkowo poniżej progu 0,80 zanotowano dla sieci 3 i podzbioru walidacyjnego ( $r = 0,71$ ). Niemniej jednak, nawet w tym przypadku, stwierdzony błąd średni wynoszący 1,19, był niski w stosunku do najwyższej, spośród wszystkich podzbiorów danych, wartości średniej wskaźnika Rr ( $62,70 \text{ MJ}\cdot\text{ha}^{-1}\cdot\text{cm}\cdot\text{h}^{-1}$ ).

Wartości współczynnika korelacji w obrębie całego zbioru danych zmieniały się dla poszczególnych sieci, jedynie w wąskim zakresie od  $r = 0,87$  w przypadku sieci 1 do  $r = 0,83$  w przypadku sieci 3. Ogólnie jakość prognoz otrzymywanych z wszystkich trzech sieci była bardzo zbliżona. Nie można było zauważyć istotnego wpływu architektury sieci, na przykład zdublowanej warstwy neuronów ukrytych, na jakość wyników z nich otrzymywanych.

Na rysunku 3 przedstawiono otrzymane przy użyciu sieci 1 prognozy średnich rocznych wartości wskaźnika Rr na tle rzeczywistych jego wartości. Na wykresie tym widoczny jest bardzo dobrze układ punktów zbliżony do linii o nachyleniu 1:1, co wskazuje na bliskość prognoz względem wartości docelowych. Wartym podkreślenia jest fakt, że prognozy dla trzech najwyższych wartości wskaźnika Rr, przekraczających  $110 \text{ MJ}\cdot\text{ha}^{-1}\cdot\text{cm}\cdot\text{h}^{-1}$  były bardzo zbliżone do wartości rzeczywistych. Jest to sytuacja całkowicie odmienna względem dużych rozbieżności obserwowanych w przypadku stosowania zmodyfikowanego indeksu Fourniera (patrz rys. 1).



**Rys. 3.** Rzeczywiste i przewidywane przez sieć 1 wartości Rr

**Fig. 3.** Real versus predicted by net 1 Rr values



## WNIOSKI

Przeprowadzone badania wykazały możliwość praktycznego stosowania techniki sztucznych sieci neuronowych dla określania średniej rocznej wartości wskaźnika erozyjności deszczy, na podstawie znajomości jedynie średnich miesięcznych sum opadów. Dla tego celu mogą być stosowane z równym powodzeniem sieci typu perceptronowego o pojedynczej lub podwójnej warstwie ukrytej, jak też sieci o radialnych funkcjach bazowych. Dokładność otrzymywanych przy użyciu sztucznych sieci neuronowych prognoz średnich rocznych wartości wskaźnika  $R_r$ , wydaje się być w pełni wystarczająca dla użycia ich wartości dla przybliżonego szacowania średnich z wielolecia rocznych strat gleby według równania USLE oraz dla oceny potencjalnego i rzeczywistego zagrożenia procesami erozji wodnej gleb. Jednocześnie należy stwierdzić, że określanie średniej rocznej wartości wskaźnika  $R_r$  za pomocą zmodyfikowanego wskaźnika Fourniera na podstawie jedynie średnich miesięcznych sum opadów w warunkach środkowo-europejskich jest obciążone bardzo dużym błędem i nie może być podstawą dla dalszego modelowania i opisu zjawiska erozji wodnej gleb.

## PODZIĘKOWANIE

Autor pragnie podziękować Fundacji na Rzecz Nauki Polskiej za wsparcie badań w ramach stypendium krajowego dla młodych naukowców.

## PIŚMIENNICTWO

1. **Banasik K., Górski D.:** Ocena erozyjności deszczy dla trzech wybranych stacji Polski południowo-wschodniej. Zesz. Nauk. AR we Wrocławiu, Melioracje XL, 211, 39-50, 1992.
2. **Banasik K., Górski D., Mitchell J.K.:** Rainfall erosivity for east and central Poland. Proceedings of the International Symposium & Exhibition on Soil erosion Research for the 21<sup>st</sup> Century, January 3-5, Honolulu, Hawaje, USA, 279-282, 2001.
3. **de Santos Loureiro N., de Azevedo Coutinho M.:** A new procedure to estimate the RUSLE EI30 index, based on monthly rainfall data and applied to the Algarve region, Portugal. Journal of Hydrology, 250, 12-18, 2001.
4. **Gabriels D.:** Rainfall erosivity and rainfall concentration in Europe. COST 623 Final Conference "Soil Erosion and global Change", July 5-8, Budapest, Hungary, 2003.
5. **Goovaerts P.:** Using elevation to aid the geostatistical mapping of rainfall erosivity. Catena, 34, 227-242, 1999.
6. **Górski D., Banasik K.:** Rozkłady prawdopodobieństwa erozyjności deszczy dla Polski południowo-wschodniej. Zesz. Nauk. AR w Krakowie, Sesja naukowa 35, 271, 125-131, 1992.
7. **Józefaciuk A., Józefaciuk C.:** Erozja agroekosystemów. Biblioteka Monitoringu Środowiska, Warszawa, 1995.
8. **Licznar P.:** Modelowanie erozji wodnej gleb. Zesz. Nauk. AR we Wrocławiu, Monografie XXXII, 456, 2003.

9. **Licznar P.:** Sieci neuronowe w modelowaniu procesów meteorologicznych. W: Wybrane zagadnienia z zakresu pomiarów i metod opracowania danych automatycznych stacji meteorologicznych. (praca zbiorowa pod red. J. Łomotowskiego i M. S. Rojka), Zesz. Nauk. AR we Wrocławiu, Monografie XXV, 428, 2001.
10. **Licznar P., Nearing M.A.:** Artificial neural networks of soil erosion and runoff prediction at the plot scale. *Catena*, 51(2), 89-114, 2003.
11. **Licznar P., Rojek M.:** Erozyjność deszczy Polski południowo-zachodniej na przykładzie stacji Wrocław-Swojec. *Przeg. Nauk. SGGW, Inżynieria i Kształtowanie Środowiska*, Rocznik XI, 2(25), 7-14, 2002.
12. **Renard K.G., Freimund J.R.:** Using monthly precipitation data to estimate the R-factor in the revised USLE. *Journal of Hydrology*, 157, 287-306, 1994.
13. **Sauerborn P.:** Die Erosivität der Niederschläge in Deutschland – Ein Beitrag zur quantitativen Prognose der Bodenerosion durch Wasser in Mitteleuropa. *Bonner Bodenkundl. Abh.* 13, Bonn, 1994.
14. **Sauerborn P., Klein A., Botschek J., Skowronek A.:** Future rainfall erosivity derived from large-scale climate models – methods and scenarios for a humid region. *Geoderma*, 93, 269-276, 1999.
15. **Švehla F., Skořepa Z.:** Úprava podkladů pro stanovení hodnot faktorů K a R ve Wischmeier-Smithově vzorci. *Pozemkové úpravy, Červen*, 12-13, 1995.
16. **Wischmeier W. H., Smith D. D.:** Predicting rainfall erosion losses. A guide to conservation planning. *Agricultural Handbook*, No. 537, ARS, Washington, 1978.

## EVALUATION OF ARTIFICIAL NEURAL NETWORKS APPLICATION POSSIBILITY FOR MEAN ANNUAL RAINFALL EROSIIVITY FACTOR VALUE ESTIMATION

*Paweł Licznar*

Institute of Building and Landscape Architecture, University of Agriculture  
pl. Grunwaldzki 24, 50-363 Wrocław  
e-mail: licznarp@ozi.ar.wroc.pl

**Abstract.** Rainfall erosivity factor is one of the most poorly assessed parameters of Universal Soil Loss Equation (USLE) in Poland. Evaluation of artificial neural networks application possibility for mean annual rainfall erosivity factor value estimation only on the basis of known mean monthly precipitation was the main aim of the research. The research was based on the database from 90 gauging stations from the area of Poland and Germany. Within the frame of the conducted evaluation, the application possibility of single or double hidden layer perceptron and radial base networks for a chosen aim realization was examined. It was proved that satisfactory results of mean annual rainfall erosivity factor values estimation were obtained on the basis of known mean monthly precipitation by means of perceptron artificial neural networks of one or two hidden layers and radial base networks. At the same time, the research showed a failure of Modified Fournier Index application for this purpose.

**Key words:** rainfall erosivity factor, artificial neural networks, Modified Fournier Index