

# BUDOWA NEURONOWYCH MODELI PROGNOSTYCZNYCH NA PRZYKŁADZIE WYBRANYCH ZAGADNIEŃ INŻYNIERII ROLNICZEJ

Streszczenie

*Celem pracy było omówienie metodyki budowy modeli prognostycznych w oparciu o sztuczne sieci neuronowe. Podczas konstruowania modelu neuronowego realizującego predykcję występują często złożone problemy. Z uwagi na to przybliżono metody pozwalające na poprawny przebieg poszczególnych etapów budowy. Przedstawiono również wartość poznawczą i skuteczność działania tych modeli dla inżynierii rolniczej.*

## Wstęp

Budowa modeli prognostycznych ma na celu uzyskanie na temat danego zagadnienia informacji dotyczących przyszłości. Jest to wiedza istotna dla podejmowania działań w czasie rzeczywistym i często decydująca o strategii finansowej jednostki decyzyjnej. Potrzeba prognozowania, rodząca się w coraz intensywniej rozwijającym się informacyjnie społeczeństwie jest przyczyną powstania często złożonych systemów predykcyjnych. Zestawienia, wykresy, założenia, plany, stanowią niejednokrotnie bazę wiedzy, na podstawie której buduje się prognozy, niosące spojrzenie na przyszłe zjawiska z perspektywy teraźniejszej.

Zbudowany model neuronowy powinien dostarczać możliwie najbardziej precyzyjnych informacji. Żeby tak się stało, konieczne jest oprócz przygotowania prawidłowego zbioru uczącego, odpowiednie przeprowadzenie samego procesu uczenia. Należy umiejętnie dobrać warunki uczenia sztucznej sieci neuronowej, zwracając uwagę na wybór odpowiedniej topologii sieci, algorytmów uczenia, liczby epok itd. Wszystkie te elementy będą wpływały na poziom jakości modelu, który można zweryfikować m.in. wykorzystując analizę wrażliwości nauczonej sieci neuronowej. Praktyczne wykorzystanie modeli neuronowych w zagadnieniach inżynierii rolniczej jest coraz szersze z uwagi na wzrastający popyt na prognozy. Spowodowany jest on m.in. brakiem pewności związanej z przyszłością, a co za tym idzie chęcią posiadania coraz to dokładniejszych informacji na jej temat. Zaletą sieci neuronowych jest możliwość pracy przy dużej ilości danych, przetwarzania informacji rozmytych, niekompletnych lub zaszumionych. Wyróżnić można następujące etapy budowy modeli prognostycznych:

- formułowanie problemu badawczego,
- gromadzenie zmiennych mogących wpływać na dane zjawisko,
- wybór metody prognostycznej,
- budowanie zbioru uczącego,
- uczenie sztucznej sieci neuronowej oraz jej modelowanie,
- testowanie wygenerowanego modelu prognostycznego,
- integracja modelu predykcyjnego z środowiskiem „przyjaznym” użytkownikowi.

## Formułowanie problemu badawczego

Ten początkowy, inicjujący etap tworzenia modelu prognostycznego pozwala na wybór przedmiotu, charakteru oraz zakresu podejmowanego problemu predykcyjnego. Przewidywać można zagadnienia z różnorodnych dziedzin

oraz o różnym zasięgu. Należy jednak wziąć pod uwagę dostępność danych uczących, na podstawie których będzie budowany model predykcyjny. Na tym etapie trzeba też pamiętać, że najdokładniejszymi prognozami są predykcje krótkoterminowe (tzn. przeprowadzane dla możliwie małych odstępów czasu). Dokładność wyniku prognozy kształtuje się zgodnie z zależnością: im dalej w przyszłość się przewiduje, tym jest ona mniej dokładna. Osoba budująca sztuczną sieć neuronową, na tym etapie, powinna w szczególności wiedzieć, co chce przewidywać oraz jakie zmienne uczące mogą mieć znaczenie w kształtowaniu się danego problemu predykcyjnego.

## Gromadzenie zmiennych mogących wpływać na dane zjawisko

Kluczem do budowy modelu prognostycznego jest zgromadzenie adekwatnego zbioru danych w celu przygotowania zbioru uczącego. Jest to jeden z ważniejszych etapów, zmierzających do uzyskania neuronowego modelu predykcyjnego. Taki zbiór powinien składać się z niezależnych zmiennych wejściowych (na ich podstawie formułuje się prognozę) i wyjściowych (prognozowanych). Istotne jest, aby efekt działania zbudowanego modelu dostarczał możliwie precyzyjnych informacji, gdyż „duszący nadmiar informacji, paraliżujący dzisiaj rozwój i wykorzystanie technik informatycznych, jest produktem ubocznym upowszechnienia i rozproszenia procesów wytwarzania, gromadzenia, przetwarzania i przesyłania informacji” [9].

## Wybór metody prognostycznej

Na etapie przygotowania danych precyzuje się metodę, którą wykorzystuje się w celu uczenia modelu neuronowego. Dostępność odpowiednich danych warunkuje wykorzystanie metody. Jeśli dany problem badawczy jest przypuszczalnie rozwiązywalny przy użyciu różnych informacji opisujących ten problem, właściwe jest wybranie do uczenia np. metody regresji wielorakiej. Rozwiązanie to pozwala na odnalezienie związków między badanymi cechami oraz na zbudowanie modelu regresyjnego, opisującego powiązania między tymi cechami a zmienną wyjściową. W przypadku, gdy nie dysponuje się zmiennymi opisującymi dane zjawisko, ale dysponuje się przeszłymi wartościami zmiennej prognozowanej, zasadne jest wybranie np. metody szeregów czasowych. Pozwala to na ustalenie predykcji zmiennej w oparciu o wartości, które zmieniają się w czasie. Złożoność danych jest więc jednym z kryterium wyboru metody uczenia modelu prognostycznego.

Zmienne należące do zbioru uczącego powinny odznaczać się uzasadnioną potrzebą ich użycia. Przydatność taką można określić zarówno przed rozpoczęciem uczenia sztucznej sieci neuronowej jak i kontrolować w trakcie tego procesu. W pierwszym przypadku wstępną ocenę zmiennych umożliwia przeprowadzenie np. doboru cech. Metoda ta pozwala na wyeliminowanie zmiennych nieprzydatnych w procesie uczenia. Kontrola użyteczności zmiennych w trakcie procesu uczenia może być realizowana przez wgląd w analizę wrażliwości modelu na poszczególne zmienne wejściowe.

Poszczególne przypadki przygotowanego zbioru uczącego są zaliczone do podzbiorów: uczącego, walidacyjnego bądź testowego. Dzielone są one domyślnie, odpowiednio w proporcjach 2:1:1. Podzbiór uczący służy do uczenia sieci, walidacyjny do niezależnego sprawdzenia jakości uczonej sieci (niezbędny dla uniknięcia "przeuczenia"), natomiast podzbiór testowy do sprawdzenia jakości gotowej już sieci (przypadki należące do tego podzbioru nie są używane w procesie uczenia). Liczba przypadków uczących powinna być co najmniej kilka razy większa niż liczba połączeń sieci neuronowej.

W przypadku modelu predykcyjnego, przewidującego cenę ziemniaków, zbudowanego dla potrzeb pracy pt. „Sieci neuronowe jako narzędzie predykcyjne w procesie prognozowania cen ziemniaków” [1], wykorzystano dane charakteryzujące bezpośrednio tą roślinę, dane meteorologiczne oraz dane wskaźnikowe. Do pierwszej grupy należały: przeciętna cena skupu ziemniaków - *CeZiem* [zł/10<sup>1</sup>t], skup ziemniaków - *SkuZiem* [tys. ton], eksport ziemniaków - *Eksp* [ton] oraz import ziemniaków - *Imp* [ton]. Druga grupa składała się z: średniej temperatury powietrza - *TempPow* [°C], średniej temperatury gruntu na głębokości 5 cm - *TempGru* [°C] i sumy opadów - *SumOpa* [mm]. Do danych wskaźnikowych należały: wskaźnik zmiany cen paliwa - *WskCePal* [-], wskaźnik zmiany cen spirytusu - *WskCeSpi* [-], przeciętna cena skupu pszenicy - *CePsze* [zł/10<sup>1</sup>t].

Zgromadzone dane zostały poddane ocenie przydatności, dzięki której wywnioskowano, że najmniejszą wartość dla modelu predykcyjnego wykazują zmienne: suma opadów oraz eksport ziemniaków. Postanowiono wykluczyć te zmienne z procesu uczenia sieci, co w rezultacie poprawiło wynik otrzymanego modelu (błędu testującego, walidacyjnego oraz uczącego). Wyeliminowano w ten sposób nieprzydatne informacje ze zbioru uczącego. Fragment tego zbioru, użytego do budowy opisanego modelu przewidującego cenę ziemniaków przedstawia tab. 1.

Tab. 1. Fragment zbioru zmiennych użytych do budowy modelu przewidującego cenę ziemniaków metodą regresji wielorakiej (przykładowe dane za rok 2006)

Tab. 1. The part of gathering of variables used to the buildings of model foreseeing the potatoes' price with the use of manifold regression (examples - data gathered in 2006)

CeZiem	CePsze	TempPow	TempGru	WskCeSp	WskCePal	SkuZie	Imp
54,10	39,65	8,3	8,5	100,1	105,2	39,1	22215
51,98	41,09	13,1	14,5	100,1	103,4	32,4	36741
53,23	41,90	17,0	19,4	100,2	99,7	29,4	12748
47,37	40,82	21,9	25,1	100,0	102,1	21,9	519
44,02	43,51	17,4	19,2	100,0	102,5	36,7	3764
24,52	49,38	15,6	16,1	100,1	97,5	159,6	2636
18,38	50,37	10,5	10,7	100,0	95,0	326,9	713
21,34	53,58	5,6	5,3	100,0	97,5	133,7	1658
38,88	57,25	3,7	3,1	100,0	96,0	45,4	2542

Jest to istotny etap budowy modelu neuronowego, w którym szereg różnorodnych czynników wpływających na prognozowane zagadnienie może utrudniać jego realizację. Od prawidłowo przeprowadzonego procesu uczenia zależy jakość wyników generowanych przez sieć. Proces ten przeprowadza się wykonując symulacje modeli prognostycznych na różnych topologiach i przy użyciu różnych algorytmów uczenia. Takie „testowanie” topologii oraz algorytmów uczących sieci neuronowych umożliwia wybór właściwej sieci, tzn. takiej, która możliwie najlepiej radzić sobie będzie z rozwiązywaniem danego problemu i która obciążona będzie najmniejszymi błędami uczącymi. Do rozwiązywania problemów predykcyjnych najczęściej wykorzystuje się takie typy sieci, jak: perceptron wielowarstwowy oraz sieci o radialnych funkcjach bazowych. Dla pierwszego typu sieci istotne jest dobranie rodzaju algorytmu uczącego (spośród m.in.: wstecznej propagacji błędów, gradientów sprzężonych, Quasi-Newtona, Levenberga-Marquardta, szybkiej propagacji itd.), szybkości uczenia, liczby epok uczenia w fazie pierwszej oraz drugiej. Często praktykuje się technikę treningu polegającą na wykorzystaniu algorytmu wstecznej propagacji błędów (w pierwszej fazie uczenia) i algorytmu gradientów sprzężonych (w drugiej). Dla sieci o radialnych funkcjach bazowych dobrać można parametry funkcji bazowych. Istotne są tutaj centra (naturalne skupienia wartości), które można wyznaczyć np. metodą powtórnych próbkowania lub algorytmem k-średnich. W modelach neuronowych przewidujących cenę ziemniaków, w pracy pt. „Sieci neuronowe jako narzędzie predykcyjne w procesie prognozowania cen ziemniaków” [1], najlepszymi sieciami pod względem ich charakterystyk i statystyk regresyjnych okazały się sieci typu perceptron wielowarstwowy. Predykcje realizowane były z wykorzystaniem metody szeregów czasowych oraz regresji wielorakiej.

Podczas realizacji procesu uczenia należy zwrócić uwagę na niedopuszczenie do przeuczenia sieci. Łatwo jest wtedy uzyskać dowolnie mały błąd dla podzbioru uczącego generując sieć, która będzie doskonale sobie radzić z tym podzbiorem. Jednak w przypadku podzbioru testowego czy walidacyjnego wyniki byłyby nieprawidłowe. Czas uczenia sieci zależy od stopnia złożoności podejmowanego problemu. Kontrolować należy wartości błędów odpowiednio dla podzbioru walidacyjnego, uczącego oraz testowego.

**Testowanie wygenerowanego modelu prognostycznego**

Zaprojektowane i zbudowane sieci neuronowe poddaje się ocenie i testowaniu. Pod uwagę należy wziąć ich efektywność.

Sieci te ocenia się m.in. na podstawie statystyk podsumowujących modele. Istotny jest współczynnik jakości dla podzbioru uczącego, walidacyjnego oraz testującego jak również współczynnik błędów tych podzbiorów. Uczenie ma na celu minimalizację błęd, dlatego na szczególną obserwację zasługuje błąd RMS (ang. *Root Mean Square* - pierwiastek z błędu średniokwadratowego). Wyznaczany jest on w oparciu o wartość błędów jednostkowych obliczanych za pomocą funkcji błędu. W momencie, kiedy krzywa błędów dla dowolnego podzbioru wzrasta, zaprzestaje się dalszego procesu uczenia. Zabieg ten nie dopuszcza do przeuczenia sieci.


Oszacowanie poprawności funkcjonowania sieci ułatwia wykreślenie powierzchni odpowiedzi. Zestawione jest wówczas wyjście modelu neuronowego w funkcji wybranej zmiennej wejściowej. Wykres taki jest wtedy jednowymiarowym przekrojem przez powierzchnię odpowiedzi. Ułatwia obserwację zmian wartości wybranej zmiennej wejściowej w poszczególnych zakresach oraz interpretację zależności naniesionych na tą powierzchnię odpowiedzi zmiennych.

Kolejnym etapem testowania modeli prognostycznych jest uruchomienie nauczonej sieci w celu dokonania predykcji. Zadaniem sztucznej sieci jest praca na danych, które nie zostały użyte w procesie uczenia, dlatego takie dane należy wprowadzić na wejście działania sieci. Otrzymuje się w ten sposób wynik predykcji, który zestawia się z prawidłowym, rzeczywistym wynikiem. Określa się tym samym błąd predykcji.

Testowanie przeprowadza się często według metody korekt modelowych. Sposób ten polega na tym, iż w momencie uzyskania niezadowolających wyników następuje powrót do etapu budowy sieci. Można wtedy wielokrotnie dobrać parametry uczące dla sieci.


### Integracja modelu predykcyjnego z środowiskiem „przyjaznym” użytkownikowi

Etap ten jest istotny ze względów użytecznych. Wytworzony model predykcyjny zazwyczaj jest częścią aplikacji programistycznej, która umożliwi użytkownikowi korzy-



Rys. 1. Okno główne oraz okna wyboru metod programu „Pyrka”

Fig. 1. The main window and window of choice of methods programme "Pyrka "



Rys. 2. Diagram przypadków użycia

Fig. 2. Use case diagram

stanie z niego. Aplikacja ta powinna być zaprojektowana zgodnie z przeprowadzoną analizą wymagań funkcjonalnych i nie-funkcjonalnych. Ułatwia ona precyzyjne ustalenie potrzeb, które powinien spełniać system. Przykładem integracji modelu predykcyjnego z środowiskiem „przyjaznym” użytkownikowi jest aplikacja o nazwie „Pyrka”. Wytworzona została ona na potrzebę użytkowników predykcyjnego modelu neuronowego, umożliwiającego przewidywanie cen ziemniaków. Dopiero takie połączenie modelu neuronowego wraz z środowiskiem użytkownika daje możliwość pełnego wykorzystania funkcjonalności zbudowanego modelu przez osoby o różnych umiejętnościach informatycznych.

### Podsumowanie

Proces budowy modelu predykcyjnego ma często bardzo złożony charakter. Oddziaływanie szeregu różnorodnych czynników egzogenicznych oraz endogenicznych nie ułatwia poszukiwania właściwego rozwiązania. Wśród tak wielu zależności trudno jest jednoznacznie odróżnić te czynniki, które mają istotny wpływ, od tych, które są jedynie zakłóceniami.

Sieci neuronowe stanowią niejednokrotnie właściwe rozwiązanie w sytuacjach, kiedy dane cechują się nieregularnością. Są w stanie wyuczyć się wzorców, nabywając przy tym zdolność uogólniania wiedzy. Istotne jest odpowiednie przeprowadzenie poszczególnych etapów budowy modelu, gdyż od tego procesu zależy jakość osiąganych predykcji. Modele neuronowe ułatwiają analizę rynku, podejmowanie kluczowych decyzji, dostarczają dodatkowych informacji związanych z danym problemem. Wszystkie te zadania mogą być zrealizowane przez predykcyjne sieci neuronowe na

zadawalającym poziomie dokładności, w szczególności przy założeniu, że prognoza ma charakter krótkoterminowy.

### Literatura

- [1] Błaszczyk M., Dejevska T.: Sieci neuronowe jako narzędzie predykcyjne w procesie prognozowania cen ziemniaków. Praca magisterska. Uniwersytet Przyrodniczy w Poznaniu, Poznań 2008.
- [2] Boniecki P.: Elementy modelowania neuronowego w rolnictwie. WUP Poznań 2008.
- [3] Duch W., Korbicz J., Rutkowski L., Tadeusiewicz R.: Sieci neuronowe. Akademicka Oficyna Wydawnicza Exit, Warszawa 2000.
- [4] Francik S.: Prognozowanie ceny ogórka szklarniowego za pomocą sieci neuronowych, *Inżynieria Rolnicza*, 2005, nr 14(74). s. 91-97.
- [5] Koszela K., Boniecki P., Weres J.: Ocena efektywności neuronowego prognozowania w oparciu o wybrane metody na przykładzie dystrybucji produktów rolniczych. *Inżynieria Rolnicza*, 2005, nr 2 (62). s. 69-76.
- [6] Niedbała G., Przybył J., Boniecki P., Sęk T., 2005. Analiza założeń dla modelowania plonu buraka cukrowego z wykorzystaniem sztucznych sieci neuronowych. *Inżynieria Rolnicza*. Nr 2 (62). s. 123-130
- [7] Osowski S.: Sieci neuronowe w ujęciu algorytmicznym. Wydawnictwo Naukowo-Techniczne, Warszawa 1996.
- [8] Osowski S.: Sieci neuronowe do przetwarzania informacji. Wydawnictwo Politechniki Warszawskiej, Warszawa 2000.
- [9] Tadeusiewicz R.: W dymie i mgłę. *ComputerWorld*, 1999, nr 37, ss. 60-62.

## CONSTRUCTION OF NEURAL FORECASTING MODELS FOR EXAMPLE OF SELECTED ISSUES IN AGRICULTURAL ENGINEERING

### Summary

*The aim of the following thesis was the description of methods of building of prognostic models with the use of the artificial neural networks. During constructing of neuronal model of prediction, a variety of complex problems may often appear. In consideration of those problems, some methods enabling appropriate course of each of the stages of building the model were presented. Moreover, a cognitive value and effectiveness of working of those models in the agricultural engineering were introduced.*