

Krystyna Filipiak

*Instytut Uprawy Nawożenia i Gleboznawstwa - Państwowy Instytut Badawczy
w Puławach*

ILOŚCIOWE METODY PROGNOZOWANIA W ROLNICTWIE*

Wstęp

Prognozowanie jest naukowym sposobem przewidywania, w jaki sposób będą kształtowały się w przyszłości procesy lub zdarzenia. Metoda prognozowania (konstruowania prognoz) obejmuje budowę modelu prognostycznego oraz regułę prognozowania. Model odwzorowuje prawidłowości zachodzące w przeszłości bądź zakładane, że będą występowały w przyszłości w prognozowanym zjawisku (np. kształtowanie się struktury obszarowej gospodarstw rolnych) lub pomiędzy prognozowanym zjawiskiem a innymi zjawiskami. Mogą to być prawidłowości występujące w rozwoju prognozowanego zjawiska – częstość, tendencja rozwojowa, wahania okresowe itp. lub pomiędzy zjawiskiem prognozowanym a innymi zjawiskami – zależności przyczynowo-skutkowe, zależności symptomatyczne (współlistnienia), podobieństwo rozwoju itd.

Z uwagi na charakter prognozowanych zjawisk można je podzielić na ilościowe, gdy wynik prognozy jest wyrażony liczbowo, albo jakościowe, gdy wynik prognozy jest wyrażony opisowo (słownie), co implikuje również podział modeli prognostycznych na modele formalne, które mają na ogół postać równania (równań) oraz modele nieformalne (myślowe).

Prognozy ilościowe tworzy się, wykorzystując wiele różnych metod z zakresu matematyki i statystyki. Wyróżnia się tu metody projekcyjne, które są oparte na modelu przeszłych zdarzeń oraz metody przyczynowe, bazujące na analizach przyczyn i ich skutkach. Na przykład, znając zależność między plonem zbóż i wskaźnikiem waloryzacji rolniczej przestrzeni produkcyjnej możemy z dużym prawdopodobieństwem ocenić przyszłe zbiory zbóż w określonych warunkach siedliskowych.

Prognozowanie znajduje szczególne zastosowanie w ekonomii i zarządzaniu (2-5, 7-9, 12-14, 16, 23, 24, 26). Obecnie stosuje się coraz częściej metody ilościowe do prognozowania w rolnictwie (1, 4, 6, 10, 11, 15, 17, 18-22, 25).

* Opracowanie wykonano w ramach zadania 2.1. w programie wieloletnim IUNG - PIB.

Podstawowe założenia teorii predykcji

Predykcja to reguła pozwalająca na wyznaczenie najlepszego w danych warunkach przybliżenia przyszłej realizacji zmiennej prognozowanej. Zasada predykcji określa sposób budowy prognozy na podstawie modelu:

- znany jest oszacowany model wyjaśniający kształtowanie się zmiennej, dla której budujemy prognozę;
- struktura opisywanych przez model zjawisk jest stabilna w czasie (nie zmienia się postać analityczna modelu, nie występują zmiany parametrów strukturalnych modelu oraz struktura powiązań przyczynowych jest stała w czasie, nie zmienia się zestaw przyczyn);
- znane są wartości zmiennych objaśniających w okresie prognozowanym;
- rozkład składnika losowego nie ulega zmianom w czasie (jest stały);
- dopuszczalna jest ekstrapolacja modelu poza obszar zmienności zmiennych objaśniających obserwowanych w próbie (gdzie $\bar{x} \pm S(x)$ – obszar zmienności), jeżeli zmienne objaśniające przekraczają ten obszar to mamy do czynienia z modelem trendu.

Wyróżnia się trzy sposoby wykorzystywania informacji uzyskanych z analizy przeszłości do wnioskowania o przyszłości. Z tym wiążą się predykcje: ekstrapolacyjna, przyczynowa i adaptacyjna.

Predykcja ekstrapolacyjna polega na budowie prognozy w drodze ekstrapolacji funkcji jednej zmiennej $f(t)$ na wartości zmiennej czasowej t , odpowiadającej poszczególnym okresom należącym do prognozowanego przedziału czasowego T . Metody te stosuje się wówczas, gdy zmiany zmiennej prognozowanej w czasie są analogiczne ze zmianami zmiennych objaśniających.

Predykcja przyczynowa polega na wnioskowaniu w przyszłość na podstawie poznanych ilościowych relacji przyczynowo-skutkowych. Ten sposób prognozowania wykorzystuje się w przypadku, gdy można wyróżnić jeden lub kilka czynników silnie oddziałujących na zmienną prognozowaną i przypuszcza się, że w przyszłości wartości tych czynników ulegną zasadniczym zmianom.

W **predykcji adaptacyjnej** model jest sekwencyjnie korygowany o nowe dane pozyskiwane w wyznaczonych okresach prognozowanego przedziału czasowego, co umożliwia dość szybko wykryć ewentualne załamania dotychczasowych trendów i zastąpić je nowymi zależnościami. Dlatego predykcję adaptacyjną stosuje się w przypadku, gdy zmienna prognozowana wykazuje mało regularne zachowania w czasie.

Zasada predykcji nieobciążonej polega na tym, że prognozę wyznacza się na poziomie wartości oczekiwanej zmiennej prognozowanej w okresie prognozowanym T . Stosuje się ją wówczas, gdy proces predykcji jest powtarzalny, a popełniane wtedy błędy dodatnie i ujemne równoważą się tak, że proces predykcji ani nie zawyża, ani nie zaniża przyszłych realizacji zmiennej prognozowanej.

Zasada predykcji według największego prawdopodobieństwa polega na wyznaczeniu prognozy na poziomie równym modalnej (dominancie) rozkładu zmiennej prognozowanej.

Obie zasady dają te same wyniki (prognozy), gdy rozkład zmiennej prognozowanej jest co najmniej symetryczny.

Niezależnie od zasady, którą przyjmujemy można mówić o dwóch rodzajach predykcji:

- punktowej – polega na wyznaczeniu konkretnej wartości prognozy,
- przedziałowej – polega na wyznaczeniu przedziału liczbowego, w którym rzeczywista wartość zmiennej prognozowanej znajdzie się z wysokim prawdopodobieństwem. Aby wyznaczyć prognozę przedziałową trzeba znać rozkład zmiennej prognozowanej. Najczęściej zakłada się, że rozkład zmiennej prognozowanej jest normalny.

Z wielu przyczyn prognozy nie zawsze są trafne, dlatego też ich wykorzystanie w procesie decyzyjnym, chociaż oparte na założeniu, że wyniki prognozowania będą poprawne, powinno uwzględniać błąd prognozy. Oceniając zatem zbudowaną prognozę, należy określić stopień jej niepewności. Wyróżnia się dwa rodzaje błędów predykcji:

- *ex ante* – spodziewany rząd odchyłeń rzeczywistych realizacji zmiennej prognozowanej od prognozy; błąd ten oblicza się na etapie prognozowania,
- *ex post* – wielkość rzeczywistego odchylenia wartości zmiennych prognozowanych od prognozy; błąd ten oblicza się po zrealizowaniu prognozy.

Prognozę, której stopień niepewności jest akceptowany przez jej odbiorcę nazywa się prognozą dopuszczalną. Prognoza powinna być formułowana precyzyjnie, a więc w sposób, który umożliwia jej empiryczną weryfikowalność.

Prognozowanie na podstawie modelu ekonometrycznego

Model ekonometryczny to równanie lub układ równań, które przedstawia zasadnicze powiązania ilościowe występujące między rozpatrywanymi zjawiskami ekonometrycznymi $y = f(x_1, x_2, \dots, x_n, e)$. Strukturę każdego modelu określają:

- zmienne $\rightarrow y$ – zmienna wyjaśniana przez model (zależna) i x_1, \dots, x_n – zmienne objaśniające (niezależne),
- odchylenie losowe modelu $\rightarrow e$ – jest wyrazem stochastycznego charakteru modelu. Składnik losowy odzwierciedla fakt, że zbiór zmiennych objaśniających nie wyjaśnia dokładnie kształtowania zmiennej objaśnianej, gdyż z reguły na badane zjawisko ma wpływ (oprócz uwzględnionych) wiele innych czynników,
- postać analityczna modelu $\rightarrow f$ – określana jest w trakcie budowy modelu przedstawiającego mechanizm powiązań zmiennych objaśniających ze zmienną objaśnianą.

W zależności od rodzaju prawidłowości wyróżnia się:

- modele równań opisowych, charakteryzujące związki między zmienną objaśnianą i zmiennymi objaśniającymi;
- modele rozkładu ekonomicznych zmiennych losowych służą do opisu struktury zjawisk ekonomicznych i ich rozkładu;

- modele dynamiki wahań opisują cykliczność zmian w długim przedziale czasu.

W zależności od liczby równań modele ekonometryczne dzieli się na jednorównaniowe i wielorównaniowe, w obrębie których wyróżnia się modele proste, rekurencyjne i o równaniach współzależnych.

Główną cechą metod prognozowania opartych na modelach ekonometrycznych jest budowanie prognoz na podstawie prawidłowości zaobserwowanych pomiędzy prognozowanym zjawiskiem a innymi zjawiskami. Konstrukcja modelu składa się z pięciu etapów:

- specyfikacja modelu – obejmuje określenie zmiennych objaśnianych i objaśniających oraz wybór postaci analitycznej modelu (model liniowy lub nieliniowy); wybór zmiennych do modelu ekonometrycznego jest taki sam, jak w równaniu regresji z wieloma zmiennymi niezależnymi, czyli zmienne objaśniające słabo skorelowane między sobą i silnie skorelowane ze zmienną objaśnianą; w określeniu analitycznej postaci modelu pomocne są wykresy korelacyjne oraz aprioryczna wiedza o badanym zjawisku,

- zbieranie informacji statystycznych;
- estymacja modelu, tj. szacowanie parametrów modelu ekonometrycznego klasyczną metodą najmniejszych kwadratów (KMNK). Wyróżnia się parametry strukturalne modelu (współczynniki równań regresji), charakteryzujące siłę i kierunek oddziaływania zmiennych objaśnianych na zmienne objaśniane (zakłada się, że są stałe) oraz parametry stochastyczne modelu wynikające z rozkładu składnika losowego (wariancja składnika losowego, współczynniki autokorelacji) – traktowane jako zmienne losowe;

- weryfikacja modelu – badanie istotności parametrów strukturalnych modelu, analiza składnika losowego pod kątem autokorelacji; etap ten polega na poprawianiu modelu, modyfikacji jego równań, ewentualnej zmianie postaci funkcji, a poprawiony model poddaje się ponownie procesowi estymacji. Najczęściej wykorzystuje się dwa mierniki dopasowania modelu (tzw. dopasowanie modelu do przeszłości) – współczynnik determinacji R^2 oraz odchylenie standardowe reszt Se ;

- wykorzystanie modelu do prognozowania:
 - musi mieć istotne parametry,
 - musi mieć odpowiednio wysoki stopień dopasowania modelu (dopasowanie modelu do danych empirycznych),
 - nie występuje autokorelacja składnika losowego, a wariancja jest stała,
 - parametry modelu mają sezonową interpretację ekonomiczną.

W procesie prognozowania duże znaczenie ma dopasowanie modelu do przyszłości, czyli dopuszczalność prognoz. Do oceny dopuszczalności zbudowanej prognozy używa się błędu *ex ante*.

Regresja liniowa jest przykładem prognozy przyczynowej, w której poszukuje się związku lub przyczyny, jakie można wykorzystać w prognozie. Równanie regresji przedstawia funkcyjny związek zmiennych niezależnych (opisującej) i zmiennej zależnej (opisywanej). Do szacowania parametrów strukturalnych modelu regresji wykorzy-

stuje się, podobnie jak w modelu ekonometrycznym, KMNK. Oczywiście, rzeczywiste zdarzenia nie muszą idealnie „leżeć” na prostej (krzywej lub powierzchni) regresji. Stopień dopasowania wyników do równania określa między innymi współczynnik korelacji.

Prognozowanie na podstawie modeli trendu

Szeregi czasowe są seriami obserwacji dokonywanymi w równych odstępach czasu. Miesięczna sprzedaż, koszt dnia pracy, produkcja tygodniowa są przykładami szeregów czasowych. Rozpatrując szeregi czasowe, należy mieć na uwadze główny trend i nakładające się na niego zakłócenia. Najpopularniejsze szeregi czasowe to: model stały, model o trendzie rosnącym lub model z wahaniami sezonowymi. Główną cechą metod prognozowania opartych na modelach szeregu czasowego zmiennej prognozowanej jest budowanie prognoz na podstawie prawidłowości zaobserwowanych w dotychczasowym rozwoju prognozowanego zjawiska, bez wnikania w przyczyny ich występowania. Użycie tych metod jest jednak zasadne tylko wtedy, gdy prognozowane zjawisko charakteryzuje się dużą inercją. Konstruując prognozę przyjmuje się, że w okresie, na który jest budowana prognoza, na prognozowane zjawisko będą oddziaływały te same czynniki otoczenia przedsiębiorstwa i w taki sam sposób, jak dotychczas, a realizowana strategia nie ulegnie zmianie. Metody należące do tej grupy są więc przydatne przede wszystkim do sporządzania prognoz krótkookresowych. Przetworzenie informacji o przeszłości w procesie prognozowania na podstawie szeregu czasowego następuje przez budowę odpowiedniego (do składowych szeregu) modelu formalnego, z kolei przejście od informacji przetworzonej do prognozy – przez wybór reguły prognozowania, którą najczęściej jest reguła podstawowa lub reguła podstawowa z poprawką.

W szeregach czasowych wyróżnia się składową systematyczną, będącą efektem oddziaływań przyczyn głównych na zmienną prognozowaną, oraz składową przypadkową, zwaną także składnikiem losowym lub wahaniami przypadkowymi, będącą efektem oddziaływań przyczyn ubocznych. Składowa systematyczna występuje w postaci różnych prawidłowości w rozwoju prognozowanego zjawiska: stałego poziomu zmiennej prognozowanej, trendu (tendencji rozwojowej), składowej okresowej (wahań sezonowych i cyklicznych). Ponieważ w zależności od rodzaju występujących prawidłowości dokonuje się wyboru metody prognozowania należy przeprowadzić ich identyfikację. Identyfikację postaci tych prawidłowości szeregu czasowego umożliwia m.in.: wykres danych prognostycznych, test parametryczny współczynnika korelacji Pearsona, test nieparametryczny Daniela współczynnika korelacji rang Spearmana, funkcja autokorelacji, analiza wariancji.

Wśród modeli szeregów czasowych najczęściej wyróżnia się:

- modele naiwne,
- modele średniej ruchomej,
- modele wygładzania wykładniczego,

- liniowy model Holta,
- modele trendu,
- model trendu pełzającego,
- metodę wskaźników,
- modele autokorelacyjne typu AR, ARMA i ARIMA.

Metoda naiwna ma zastosowanie do szeregów czasowych, w których wyodrębnia się stały poziom + wahania przypadkowe lub stały (liniowy) przyrost + wahania przypadkowe; może być wykorzystywana do prognoz krótkoterminowych. Zakłada się, że prognoza na czas T jest taka sama, jak poprzednia wartość zmiennej objaśnianej. Zaletą metody jest jej prostota, lecz jej dokładność jest ograniczona.

Metodę średniej ruchomej (MA) stosuje się do konstrukcji prognoz krótkoterminowych. Dla szeregu o stałym poziomie prognozę wyznacza się jako średnią arytmetyczną k ostatnich wartości zmiennej objaśnianej (k – stała wygładzania) lub jako średnią ważoną; wartości wag są ustalone przez prognozę i określają tempo „starzenia się” informacji (suma wag = 1).

W przypadku występowania w szeregu czasowym trendu jako modeli używa się:

- modeli wygładzania wykładniczego dla szeregów czasowych z trendem (liniowy model wygładzania wykładniczego, model wygładzania wykładniczego z trendem hiperbolicznym itd.). Najczęściej wykorzystuje się wygładzanie wykładnicze Browna, stałą wygładzania α wybiera się w następujący sposób: $\alpha \rightarrow 1$ – prognoza uwzględnia w bardzo dużym zakresie błędy *ex-post* prognoz wygasłych, czyli występuje silna zależność od najnowszej obserwacji, a efekt wygładzania maleje; $\alpha \rightarrow 0$ – niewielki wpływ najnowszej obserwacji, efekt wygładzania wzrasta. W liniowym modelu Holta występują dwie stałe wygładzania z przedziału (0, 1).

- różnego rodzaju analitycznych funkcji trendu (funkcji liniowej, potęgowej, wykładniczej, logarytmicznej itd.); modele szeregów czasowych z trendem mogą być addytywne (funkcja czasu + błąd) lub multiplikatywne (funkcja czasu * błąd). Pewną odmianą funkcji trendu jest model trendu pełzającego. Dostępne obserwacje (n) dzieli się na $n-k+1$ grup (k – stała wygładzania) różniących się kolejno tylko jedną obserwacją. W każdej z grup występuje trend liniowy, a prognozę konstruuje się wykorzystując algorytm wag harmonicznych.

Stosując modele wygładzania wykładniczego prognozę punktową otrzymuje się poprzez podstawienie w równaniu prognozy w miejsce zmiennej czasowej t numeru okresu, na który jest budowana prognoza. Do oceny dopuszczalności prognozy używa się błędu *ex post* prognoz wcześniejszych. Używając jako modelu prognostycznego analitycznej funkcji trendu, prognozę punktową otrzymuje się poprzez podstawienie w miejsce zmiennej czasowej t numeru okresu, na który jest budowana prognoza. Do oceny dopuszczalności prognozy używa się błędu *ex ante*. Można także wyznaczyć przedział prognozy.

Jeśli w szeregu czasowym zmiennej prognozowanej występują wahania sezonowe do prognozowania używa się m.in.:

- metody wskaźników,

- analizy harmonicznej,
- modeli wygładzania wykładniczego dla szeregów czasowych z wahaniami sezonowymi, np. modelu wygładzania wykładniczego z trendem liniowym Wintersa.

Metoda wskaźników składa się z trzech etapów: wyodrębnienia trendu, eliminacji trendu oraz wyznaczenia wskaźników sezonowości. Efektywna eliminacja trendu wymaga wygładzania danych, najczęściej stosuje się wstępne wygładzanie ruchomą średnią ze stałą wygładzania r .

Analiza harmoniczna to metoda wykorzystująca szeregi Fouriera do rozkładu funkcji okresowej na sumę prostych funkcji trygonometrycznych.

W metodzie Wintersa występują trzy parametry wygładzania: α – stała wygładzania powiązana ze średnim poziomem wartości zmiennej prognozowanej, β – stała wygładzania powiązana ze średnim przyrostem wartości zmiennej prognozowanej, γ – stała wygładzania powiązana ze średnim poziomem wskaźników sezonowości ($0 < \alpha, \beta, \gamma < 1$).

Wygładzanie autoregresyjne

Jeżeli między wartościami zmiennej prognozowanej a jej wartościami opóźnionymi w czasie występuje autokorelacja, to wykorzystuje się model autoregresyjny typu AR(p), gdzie p jest wielkością opóźnienia. Jednak najlepsze dopasowanie modelu do szeregu czasowego uzyskuje się z połączenia modeli autoregresji i średniej ruchomej, otrzymując model typu ARMA(p, q). W modelu tym zakłada się, że wielkość prognozowana w okresie t zależy od przeszłych jej wartości oraz od błędów przeszłych prognoz. Ponieważ modele autoregresyjne są modelami stochastycznymi wymagana jest stacjonarność zmiennej prognozowanej, zaś przy braku stacjonarności zmienną należy odpowiednio przekształcić. I tak, gdy brak stacjonarności wynika z istnienia sezonowości można ją wyeliminować wykorzystując metodę wskaźników, jeżeli przyczyną jest występowanie niezerowego, stałego poziomu stosuje się centrowanie (odejmowanie średniej od każdej obserwacji), zmienność wariancji można usunąć poprzez transformację Box-Coxa, a występowanie trendu można wyeliminować poprzez operację różnicowania.

Do identyfikacji odpowiedniego modelu używa się współczynników autokorelacji i autokorelacji cząstkowej. Jeżeli funkcja autokorelacji składa się z zanikających funkcji wykładniczych lub sinusoid tłumionych, a liczba współczynników autokorelacji cząstkowej istotnie różnych od zera jest bardzo mała, to powinno się stosować model autoregresyjny AR, w sytuacji odwrotnej model średniej ruchomej MA, zaś ARMA wykorzystuje się wówczas, gdy współczynniki funkcji autoregresji oraz współczynniki autokorelacji cząstkowej wykładniczo maleją do zera. Szereg czasowy nazywa się szeregiem ARIMA (p, d, q), jeżeli po wykonaniu operacji d -krotnego różnicowania staje się on szeregiem typu ARMA (p, q). Parametry modelu AR mogą być estymowane KMNK lub z układu równań Yula-Walkera. Do szacowania parametrów modeli MA i ARMA używa się najczęściej metod iteracyjnych.

Metody niekonwencjonalne

Ostatnie lata zaowocowały bogactwem opracowań całkowicie nowych, niekonwencjonalnych technik bazujących na metodach sztucznej inteligencji (4, 9, 12, 24). Metody te, zwane ogólnie algorytmami biologicznymi, stosuje się najczęściej do modelowania złożonych procesów, lecz są też wykorzystywane do prognozowania, szczególnie krótko i średniookresowego. Można tu wymienić sztuczne sieci neuronowe, logikę rozmytą, algorytmy genetyczne i programy ewolucyjne. Połączenie klasycznych metod prognozowania i metod wykorzystujących sztuczną inteligencję pozwoli stworzyć skuteczne narzędzie prognozowania.

Podsumowanie

W produkcji rolniczej ważnym czynnikiem powodującym zmiany wielu zmiennych są warunki klimatyczne. Zmieniające się pory roku powodują tzw. wahania sezonowe. Wahania te powtarzają się w tych samych mniej więcej wielkościach (względnych lub bezwzględnych) w poszczególnych okresach roku. Sezonowość wynika także z tradycji lub przyzwyczajzeń ludzi, np. sprzedaż ryb, popyt na kwiaty. Wahania sezonowe, podobnie jak wahania cykliczne, zalicza się do wahań periodycznych. O ile wahania sezonowe są krótkookresowe, powtarzają się najczęściej w przedziale jednego roku, o tyle wahania cykliczne występują w powtarzających się długookresowych odcinkach czasu. Dlatego w prognozowaniu rolniczym często wykorzystuje się szeregi czasowe.

Należy podkreślić, że ważną rolę przy wyborze metody konstrukcji prognoz odgrywają przesłanki prognostyczne, których sformułowanie pozwala prognoście przyjąć określoną postawę wobec kształtowania się prognozowanego zjawiska w przyszłości, to zaś w znacznym stopniu implikuje wybór metody prognozowania. Innych metod używamy, dysponując tylko danymi w postaci szeregu czasowego zmiennej prognozowanej (np. model trendu, model składowej periodycznej), a jeszcze innych, jeśli posługujemy się wielowymiarowymi szeregami czasowymi zmiennej prognozowanej oraz zmiennych objaśniających (np. model ekonometryczny). Istotnym czynnikiem, który decyduje o wyborze metody prognozowania, są wykryte w trakcie statystycznej analizy danych prognostycznych prawidłowości występujące w prognozowanym zjawisku lub pomiędzy prognozowanym zjawiskiem a innymi zjawiskami. Trend, wahania sezonowe i skorelowanie z innymi zjawiskami wywierają znaczny wpływ na wybór odpowiedniej metody budowy prognoz. Wybierając metodę prognozowania, bierze się pod uwagę również dokładność uzyskiwanych za jej pomocą prognoz oraz wymagania co do ich dopuszczalności. Wzrost tych wymagań pociąga za sobą konieczność stosowania bardziej skomplikowanych metod prognozowania, które pozwalają na ogół otrzymać dokładniejsze prognozy. Spośród różnych własności metod prognozowania przy wyborze metody konstruowania prognozy decydującą rolę odgrywają najczęściej: horyzont formułowanych za ich pomocą prognoz, liczba okresów, do których

odnoszą się budowane prognozy, koszty stosowania metod, a także prostota i łatwość ich stosowania. Wykorzystanie komputerów w procesie prognozowania zwiększa możliwość zastosowania wielu ilościowych metod prognostycznych, a dysponowanie odpowiednim oprogramowaniem może być jednym z czynników decydujących o wyborze danej metody.

Prowadzone przez różnych autorów badania wykazały, że nie istnieje tylko jedna metoda prognozowania, która jest optymalna w każdej sytuacji prognostycznej. Czasem bardziej trafne prognozy uzyskuje się za pomocą metod ilościowych, a innym razem za pomocą metod jakościowych. W stosowanych obecnie systemach prognostycznych często używa się metod należących do obu tych grup (ilościowych i jakościowych). Metody ilościowe są rutynowo wykorzystywane do analizy danych historycznych i przygotowania wstępnych prognoz, które następnie są przedmiotem subiektywnych ocen dokonywanych przez ekspertów – mogą oni modyfikować prognozy z punktu widzenia innych istotnych informacji oraz własnych ocen dotyczących przyszłości. Takie postępowanie prognostyczne warto stosować w praktyce, gdyż umożliwia integrację ilościowych metod prognozowania z ocenami specjalistów.

Literatura

1. B ó r a w s k i P.: Milk price volatility in Poland. Elec. JPAU, 2006, **9(2)**.
2. B r o c k w e l l P. J.: Introduction to time series and forecasting. Springer, New York, 2002.
3. C i e ś l a k M. (red.): Prognozowanie gospodarcze. Metody i zastosowania. PWN Warszawa, 1999.
4. D a c h J., N i e d b a ł a G., P r z y b y ł J.: Zastosowanie sieci neuronowych w rolnictwie. Inż. Rol., 2001, **1(8)**: 57-62.
5. D i t t m a n n P.: Prognozowanie w przedsiębiorstwie. Oficyna Ekonomiczna, Kraków, 2003.
6. D u d e k H.: Prognozowanie cen skupu mięsa drobiowego za pomocą sezonowego modelu ARIMA. Roczn. Nauk. SERiA, 2005, **7(5)**: 119-25.
7. D u n i s C. L.: Prognozowanie rynków finansowych. Oficyna Ekonomiczna, Kraków, 2001.
8. G a j d a J. B.: Prognozowanie i symulacja a decyzje gospodarcze. Wyd. C.H. Beck, Warszawa, 2001.
9. G a t e l y E.: Sieci neuronowe. WIG PRESS, Warszawa, 1999.
10. H a m u l c z u k M.: Cykliczne zmiany na rynku trzody chlewnej w Polsce. Roczn. Nauk Rol., Seria, 2006, G, **92(2)**.
11. I w a n B.: Sezonowość skupu mleka. Roczn. Nauk. SERiA, 2005, **7(2)**: 79-83.
12. J a i n L. C., M a r t i n N. M.: Fusion of neural networks, fuzzy systems and genetic algorithms. Industrial Applications, CRC Press LLC, 1998.
13. J a j u g a K. (red.): Metody ekonometryczne i statystyczne w analizie rynku kapitałowego. AE Wrocław, 2000.
14. M i k u ś J.: Prognozowanie w badaniach marketingowych. Oficyna Wydawnicza Politechniki Wrocławskiej, Wrocław, 2003.
15. N i e d b a ł a G., P r z y b y ł J., S ę k T.: Predykcja plonów buraka cukrowego przy wykorzystaniu technik neuronowych. Inż. Rol., 2005, **8(68)**: 285-291.
16. N o w a k E. (red.): Prognozowanie gospodarcze. AW Placet Warszawa, 1998.
17. Praca zbiorowa. Analiza stosowalności zagranicznych metod prognozowania plonów w warunkach Polski. IUNG Puławy, 1996, **R(339)**.

18. S t a ń k o S.: Tendencje rozwoju produkcji zbóż. Ceny zbóż i ich prognozy. Zasady skupu interwencyjnego. Łańcuch marketingowy w sektorze zbożowym. W: Produkcja i rynek zbóż. Wyd. Wiś Jutra. Praca zbiorowa pod red. J. Rozbickiego. Warszawa, 2002, 9-10, 17-20, 40-45, 64-68.
19. S t a ń k o S., I d z i k M.: Zastosowanie metody trendów prekursorów w prognozowaniu w rolnictwie na przykładzie pogłowia trzody chlewnej. Prace Naukowe AE Wrocław, 2001, **919**: 97-105.
20. S t a ń k o S., I d z i k M.: Zastosowanie różnych metod ilościowych w prognozowaniu zjawisk i procesów gospodarczych na podstawie szeregów czasowych w których występują, tendencja, wahania sezonowe i przypadkowe. W: Metody ilościowe w badaniach ekonomicznych. Zesz. Nauk. SGGW, Ekon. Org. Gosp. Żywn., 2000, **42**: 107-122.
21. S t a ń k o S.: Prognozowanie w rolnictwie. SGGW Warszawa, 1999.
22. S z e p t y c k i A., W ó j c i c k i Z.: Stan i prognoza rozwoju techniki rolniczej w Polsce do 2020 roku. Inż. Rol., 2004, **1(56)**: 147-158.
23. W e l f e A.: Ekonometria. PWE Warszawa, 2003.
24. W i t k o w s k a D.: Sztuczne sieci neuronowe i metody statystyczne. Wyd. C.H. Beck, Warszawa, 2002.
25. W ó j c i c k i Z.: Prognostyczne modele rolnictwa i techniki rolniczej. Probl. Inż. Rol., 2002, **2(36)**.
26. Z e l i a ś A.: Teoria prognozy. PWE Warszawa, 1997.

Adres do korespondencji:

dr Krystyna Filipiak
Zakład Agrometeorologii i Zastosowań Informatyki
IUNG-PIB
ul. Czartoryskich 8
24-100 Puławy
tel: (081) 886 34 21
e-mail: filipiak@iung.pulawy.pl