

MODELE PRODUKCJI SPRZEDANEJ PRZEMYSŁU W UJĘCIU METOD SZTUCZNEJ INTELIGENCJI

BARBARA WĄSIKOWSKA
Uniwersytet Szczeciński

Streszczenie

W ostatnich latach wraz z dynamicznym rozwojem informatyki i dostarczanych przez nią coraz to większych mocy obliczeniowych obserwuje się ogromny wzrost zainteresowania metodami sztucznej inteligencji w takich dziedzinach, jak: finanse, medycyna, zastosowania inżynierskie, geologia czy fizyka. W obszarze ekonomii metody te znajdują zastosowanie w prognozowaniu bankructw, notowań giełdowych, kursów walut, wskaźników finansowo-ekonomicznych, klasyfikacji przedsiębiorstw, wycenie kontraktów terminowych, spółek, nieruchomości, w ocenie wiarygodności kredytowej oraz identyfikacji klientów według przedstawianej oferty. Obecnie wiele znaczących placówek naukowych i badawczych na całym świecie zajmuje się zastosowaniami sztucznej inteligencji. Stopień zaawansowania prac pozwolił na wydzielenie kilku kierunków badań. Najważniejszymi z nich są: sieci neuronowe, logika rozmyta, algorytmy genetyczne i teoria zbiorów przybliżonych. Metody te (w szczególności sieci neuronowe i algorytmy genetyczne) pozwalają na zautomatyzowanie niektórych, bardziej uciążliwych etapów procesu modelowania, co w dużej mierze ułatwia budowę modelu danego zjawiska ekonomicznego.

Słowa kluczowe: sztuczna inteligencja, sieci neuronowe RBF, algorytmy genetyczne, teoria zbiorów przybliżonych, modelowanie zjawisk ekonomicznych.

1. Wprowadzenie

Rozwój cywilizacji, postępu technicznego i gospodarki światowej prowadzi do powstawania coraz bardziej skomplikowanej rzeczywistości ekonomicznej w otoczeniu człowieka. Zasadniczym celem pracy badacza-ekonomisty jest więc poznanie i w możliwie prosty i najdokładniejszy sposób opisanie i wyjaśnienie zjawisk ekonomicznych. Są one jednak zazwyczaj zjawiskami nieliniowymi, cechującymi się dużą liczbą zmiennych, względnie małą liczbą danych pomiarowych oraz silną, często nieliniową korelacją zmiennych. W zjawiskach tych działają różnorodne prawa ekonomiczne, zależne od warunków ekonomicznych i polityki gospodarczej państwa. Bardzo ważnym problemem jest również upływający czas. Model opisujący zjawisko ekonomiczne dla danej rzeczywistości może zupełnie nie odpowiadać stanowi przyszłemu, bowiem czynniki mające zasadniczy wpływ na to zjawisko w badanym okresie w innym czasie mogą nie mieć tak istotnego wpływu lub nawet w ogóle nie występować. Wśród innych przyczyn powodujących ogromne trudności w opisanu otaczającej nas rzeczywistości ekonomicznej można wymienić takie jak [8]:

- wpływ ludzi (rządów, ministrów, ekspertów itp.) na aktualne zależności ekonomiczne istniejące w kraju,
- istnienie wzajemnych, często bardzo skomplikowanych i trudnych do zdefiniowania powiązań między czynnikami opisującymi badane zjawisko,
- występowanie obok informacji precyzyjnej, również informacji jakościowej i rozmytej,

- możliwość występowania błędów lub luk w zebranych materiale statystycznym,
- brak możliwości zmierzenia pewnych wielkości lub brak informacji na temat kształtowania się tych wielkości w pewnych okresach wcześniejszych,
- wystąpienie procesów, które nie zostały dotychczas zidentyfikowane.

Dokonując przeglądu literatury można zauważyć, że najczęściej stosowanymi metodami służącymi do identyfikacji czynników istotnie wpływających na badane zjawisko są metody klasyczne w postaci metod ilościowych – statystycznych i ekonometrycznych. Używając pojęcia „metody klasyczne” autorka niniejszego artykułu ma na myśli metody wcześniej opracowane, częściej wykorzystywane niż inne, stosowane przy często powtarzających się założeniach. Natomiast pojęcie „metody niestandardowe” odnosi się do metod nowych, rzadziej używanych do opisu zjawisk ekonomicznych – metod sztucznej inteligencji. By móc rzetelnie przedstawić możliwości stosowania tych metod do opisu problemów makroekonomicznych autorka artykułu zdecydowała się zastosować je do budowy modelu *produkcji sprzedanej przemysłu*, która jest jednym z głównych problemów polskiej gospodarki. Poniżej zaprezentowane zostały trzy metody sztucznej inteligencji mogące służyć do identyfikacji czynników istotnie wpływających na *produkcję sprzedaną przemysłu* tj. sztuczną sieć neuronową RBF, algorytm genetyczny oraz teoria zbiorów przybliżonych.

2. Model produkcji sprzedanej przemysłu skonstruowany w oparciu o sztuczne sieci neuronowe RBF

Niezależnie od tego jaka metoda zostanie użyta do opisu badanego zjawiska w pierwszym kroku należy ustalić zbiór kandydatek na zmienne objaśniające. Główną przesłanką, decydującą o wyborze zmiennych, powinna być ich merytoryczna wartość przy jednoczesnym uwzględnieniu celu badania [6]. Często w doborze kandydatek na zmienne posługuje się również metodą ekspercką, w której wykorzystuje się doświadczenia specjalistów (teoretyków i praktyków) z dziedziny będącej przedmiotem modelowania [5]. Jednak przede wszystkim, należy kierować się istniejącą teorią ekonomii.

Poszukując zmiennych potencjalnie wpływających na wielkość *produkcji sprzedanej przemysłu* w Polsce, poza wskazaniami płynącymi z ogólnych teorii ekonomii, oparto się m.in. na wynikach badań przeprowadzonych przez *Instytut Badań nad Gospodarką Rynkową*, wynikach przedstawionych w poszczególnych numerach *Monitora Ekonomicznego PSE S.A.*, *Biuletynu Ekonomicznego Ministerstwa Spraw Zagranicznych*, *Makro Trendów* wydawanych przez BGŻ S.A., raportów umieszczonych na stronie internetowej *eGospodarka.pl* oraz analiz opracowywanych przez *Centrum Analiz Społeczno-Ekonomicznych*. Wytypowanych zostało dwadzieścia jeden zmiennych potencjalnie wpływających na produkcję sprzedaną przemysłu: *eksport towarów ogółem*, *import towarów ogółem*, *saldo eksport import*, *przeciętne wynagrodzenie nominalne brutto*, *pracujący w sektorze przedsiębiorstw ogółem*, *bezrobotni zarejestrowani ogółem*, *zasilki dla bezrobotnych*, *podaż pieniądza ogółem*, *nakłady inwestycyjne*, *wpływy z podatku dochodowego od osób prawnych*, *wpływy z podatku dochodowego od osób fizycznych*, *kurs dolara*, *przychody z całokształtu działalności*, *koszty uzyskania przychodów z całokształtu działalności*, *wynik budżetu państwa*, *dochody budżetu państwa*, *wydatki budżetu państwa*, *wskaźnik cen produkcji sprzedanej przemysłu*, *wskaźnik cen transakcyjnych eksportu*, *inflacja miesięczna*, *liczba ludności*.

Kolejnym krokiem w prowadzonych badaniach było wybranie spośród kandydatek na zmienne objaśniające tych, które mają istotny wpływ na produkcję oraz skonstruowanie modeli *produkc-*

cji sprzedanej przemysłu przy użyciu niestandardowych metod identyfikacji zmiennych jakimi są metody sztucznej inteligencji.

Jako pierwszy zostanie przedstawiony model neuronowy RBF sprawdzający wszystkie możliwe zestawy zmiennych objaśniających. Liczbę wszystkich możliwych kombinacji zmiennych wyliczono na podstawie wzoru dwumianowego Newtona (z pominięciem oczywiście zbioru pustego, czyli braku jakichkolwiek istotnej zmiennej objaśniającej): $2^n - 1$. Zatem liczba wszystkich możliwych kombinacji, przy dwudziestu jeden kandydatkach na zmienne objaśniające, równa się: $2^{21} - 1 = 2\,097\,151$. W trakcie budowy modelu pojawił się problem ustalenia odpowiedniej ilości neuronów w warstwie ukrytej sieci neuronowej. W celu wyjaśnienia jaka liczba neuronów byłaby odpowiednia, postanowiono stworzyć po dziesięć modeli dla sieci zawierających kolejno od jednego do dwudziestu neuronów w warstwie ukrytej. W kolejnym kroku każda z sieci była trenowana na zbiorze próbek uczących przez 100 epok, a następnie testowana na zbiorze próbek walidujących. Spośród wszystkich otrzymanych modeli, wybrano po jednym, najlepszym (najniższy błąd *MSE*) dla danego rodzaju sieci. Wybranych zostało więc 20 modeli. Dla każdego z nich został policzony błąd uczący i błąd na zbiorze walidującym. Po przeanalizowaniu błędów uczących i błędów na zbiorze walidującym stwierdzono, że dla sieci zawierających od 1 do 8 neuronów w warstwie ukrytej zarówno błąd uczący, jak i błąd na zbiorze walidującym gwałtownie spada. Powyżej jednak dziewięciu neuronów wartości błędów na zbiorze walidującym zaczynają się „wahać”, tzn. raz rosną a raz spadają, co może świadczyć o przeuczeniu sieci. By uniknąć niedouczenia, jak i przeuczenia sieci stwierdzono, że najodpowiedniejszą liczbą neuronów w warstwie ukrytej będzie liczba 8. Parametry sieci zostały nastrojone automatycznie przez instrukcję *newrb* znajdującą się w programie *Matlab*.

Ostatecznie do przeprowadzenia badania użyto sieci zawierającej osiem neuronów w warstwie ukrytej. Zadaniem sieci było sprawdzenie wszystkich możliwych kombinacji oraz policzenie błędów dla każdego z otrzymanych modeli według wzoru [7]:

$$MSE = \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}, \quad (1)$$

gdzie: y_i – rzeczywista wartość zmiennej objaśnianej dla próbki i ,

\hat{y}_i – wartość zmiennej objaśnianej dla próbki, wyznaczona podstawie modelu

n – liczba obserwacji.

a następnie, podanie najlepszej kombinacji wejść dla każdego z typu modeli, czyli dla modelu zawierającego jedno wejście, dwa wejścia itd., aż do modelu zawierającego wszystkie możliwe zmienne objaśniające. Najlepszym modelem (tzn. modelem o najmniejszym błędzie) okazał się model zawierający dziesięć wejść: $X_1, X_4, X_5, X_9, X_{14}, X_{16}, X_7, X_{18}, X_{20}, X_{21}$. Wybrane spośród wszystkich kandydatek zmienne są tymi czynnikami, które wywierają największy wpływ na *produkcję sprzedaną przemysłu*.

Błąd średniokwadratowy modelu *produkcji sprzedanej przemysłu*, zbudowanego w oparciu o wybrane zmienne objaśniające, wyniósł: $MSE=0,0496$. Poniżej przedstawiono **równanie modelu**:

$$y(x) = \sum_{i=1}^8 w_i \exp\left(-\frac{\sum_{j=1}^{10} (x_j - c_{ij})^2}{2\delta_i^2}\right) + w_0, \quad (2)$$

gdzie: w_i – wagi,

x_j – zmienne objaśniające,

c_{ij} – punkt stanowiący centrum funkcji radialnej,

d – szerokość funkcji. Użyta w badaniu metoda sztucznych sieci neuronowych RBF pozwoliła na zidentyfikowanie czynników w sposób istotny wpływających na badaną produkcję. Niestety, poważną wadą tej metody jest jej bardzo duża czasochłonność.

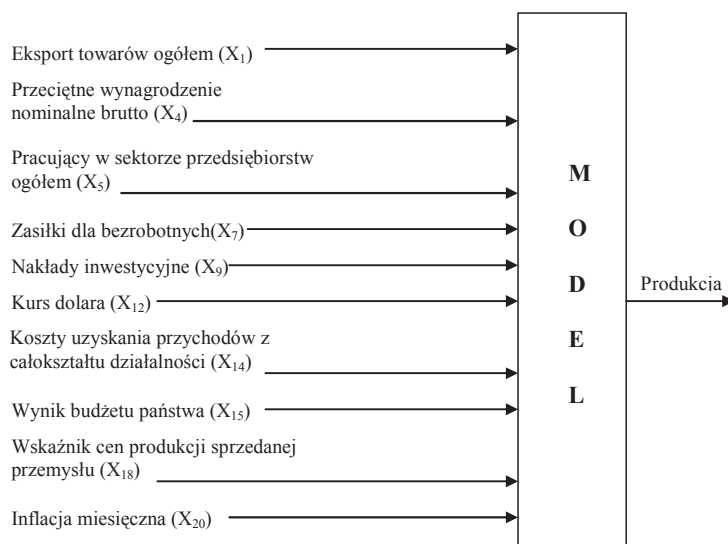
3. Model produkcji sprzedanej przemysłu skonstruowany w oparciu o algorytm genetyczny

Do budowy drugiego modelu *produkcji sprzedanej przemysłu* postanowiono użyć algorytmu genetycznego, gdyż obok sztucznych sieci neuronowych, jest to drugie pod względem popularności narzędzie sztucznej inteligencji stosowane do różnego rodzaju analiz ekonomicznych [1][2][9]. Badanie wykonane zostało przy pomocy instrukcji napisanej w programie *Matlab*. Poniżej przedstawiono opis słowny poszczególnych kroków zawartych w instrukcji:

1. Ze wszystkich możliwych kombinacji zmiennych wygenerowano drogą losową populację początkową zawierającą 20 osobników.
2. Dla każdego osobnika stworzony został model RBF, na podstawie którego obliczono wartość błędu średniokwadratowego będącego funkcją dopasowania osobnika. Osobniki posortowano rosnąco (tzn. od „najlepszego” – mającego najniższą wartość błędu, do „najgorszego” – którego wartość błędu była najwyższa), po czym $\frac{1}{4}$ najgorszych usunięto z populacji. W ten sposób przeprowadzono selekcję osobników. Pozostałe osobniki wzięły udział w kolejnym kroku modelowania jakim jest reprodukcja.
3. Reprodukcję przeprowadzono przy użyciu operatora krzyżowania. O tym, które osobniki mają brać udział w krzyżowaniu decydowały losowo stosowane funkcje AND, OR i XOR. Proces reprodukcji uznawano za zakończony, gdy liczba osobników w populacji równa była 20.
4. Otrzymałą ma drodze reprodukcji populację poddawano mutacji. Z populacji losowano pewną liczbę bitów, która ma ulec mutacji. Procesowi mutacji nie ulegał jednak osobnik, którego błąd średniokwadratowy był najniższy. Po wylosowaniu indeksów bitów (czyli miejsc, które mają ulec mutacji) następowała mutacja polegająca na zamianie 0 na 1 i odwrotnie.
5. Całą procedurę (tzn. od selekcji) powtarzano 100 razy.
6. Na końcu generowano najlepszego osobnika zapisanego w postaci chromosomu oraz błąd otrzymanego modelu.

W wyniku działania algorytmu genetycznego otrzymano chromosom składający się z 21 genów: 100110101001011001010. Geny, których wartość jest równa jedności wskazują na to, które ze zmiennych objaśniających zostały wybrane do modelu *produkcji sprzedanej przemysłu* i w sposób istotny na nią wpływają. Błąd średniokwadratowy otrzymanego modelu wyniósł: $MSE = 0,0553$ i był on większy tylko o 0,0057 od błędu modelu otrzymanego przy użyciu sieci RBF sprawdzającej wszystkie możliwe kombinacje wejść, natomiast czas oczekiwania na wyniki uległ

znacznemu skróceniu. Na rysunku 1 przedstawiono schemat opracowanego modelu produkcji sprzedanej przemysłu.



Rys. 1. Schemat modelu otrzymanego przy użyciu algorytmu genetycznego

Źródło: Opracowanie własne.

4. Model produkcji sprzedanej przemysłu skonstruowany w oparciu o teorię zbiorów przybliżonych

Pierwszym krokiem identyfikacji czynników ekonomicznych oraz budowy modelu badanego systemu jest przedstawienie zebranego materiału statystycznego w postaci tzw. pierwotnej tablicy informacyjnej. Kolejny krok polega na przekształceniu danych zawartych w tablicy informacyjnej do formy zakodowanej. W poniższym przypadku do przeprowadzenia dyskretyzacji zmiennych posłużono się programem *Analiza danych przy użyciu zbiorów przybliżonych*, działającym w środowisku *Matlab 6.0*. Zakres zmiennej objaśnianej podzielony został na trzy równe przedziały, a zakresy wszystkich zmiennych objaśniających zostały podzielone na dwa przedziały w zależności od rozkładu danej zmiennej. W wyniku przeprowadzonego kodowania, otrzymano wtórną tablicę informacyjną (tabela 1).

Głównym celem analizy danych metodą zbiorów przybliżonych jest maksymalna redukcja zmiennych oraz określenie algorytmu decyzyjnego. Cel ten można osiągnąć realizując następujące etapy:

- określenie konceptów decyzyjnych,
- redukcja liczby atrybutów warunkowych,
- budowa algorytmu decyzyjnego.

Tabela 1. Fragment wtórnej tablicy informacyjnej

U	q1	q2	...	q8	q9	q10	q11	q12	q13	...	D
p1	1	1	...	1	1	1	1	2	1	...	1
p2	1	1	...	1	1	2	1	2	1	...	1
p3	1	1	...	1	1	2	2	2	1	...	1
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
p67	2	2	...	1	2	2	2	1	2	...	2
p68	2	2	...	1	2	2	2	1	2	...	2

gdzie:

U – zbiór przykładów (obiektów); $U = \{p1, p2, p3, \dots, p96\}$

Q – zbiór atrybutów warunkowych; $Q = \{q1, q2, q3, \dots, q21\}$

D – zbiór atrybutów decyzyjnych; $D = \{d\}$

Źródło: opracowanie własne.

W pierwszej kolejności określono tzw. koncepty decyzyjne, czyli zbiory zawierające obiekty mające tą samą wartość decyzji. Po określeniu konceptów decyzyjnych podjęto próbę redukcji liczby atrybutów warunkowych. W wyniku przeprowadzonego badania otrzymano zbiór zawierający dwanaście najbardziej istotnych atrybutów warunkowych. W teorii zbiorów przybliżonych zbiór ten określa się mianem reduktu: $\{q_1, q_4, q_6, q_7, q_9, q_{11}, q_{13}, q_{14}, q_{16}, q_{17}, q_{18}, q_{20}\}$.

Atrybuty, które nie znalazły się w redukcji usunięto z tablicy decyzyjnej. Usunięte zostały, więc następujące atrybuty: $q_2, q_3, q_5, q_8, q_{10}, q_{12}, q_{15}, q_{19}, q_{21}$. Następnie w oparciu o wyznaczony redukt zbudowano algorytm decyzyjny zawierający 68 reguł w tym 14 reguł sprzecznych ze względu na atrybut decyzyjny. W kolejnych krokach podjęto próbę uproszczenia reguł podobnych i usunięcia z algorytmu decyzyjnego reguł sprzecznych. W wyniku przeprowadzonych uproszczeń, ostatecznie otrzymano siedem reguł decyzyjnych. Poniżej przedstawiono przykładową regułę i jej interpretację ekonomiczną.

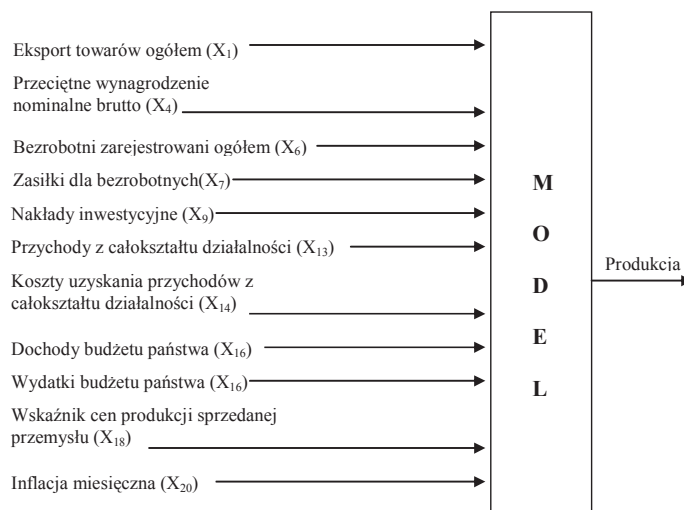
Reguła przykładowa:

Jeżeli $(q1=2)$ i $(q4=2)$ i $(q7=1)$ i $(q9=2)$ i $(q11=1)$ i $(q13=2)$ i $(q14=2)$ i $(q16=2)$ i $(q17=2)$ i $(q18=1)$ i $(q20=1)$ to $(d=3)$

Interpretacja ekonomiczna reguły przykładowej:

Jeżeli eksport towarów ogółem $\in (0,3982-1)$ i przeciętne wynagrodzenie nominalne brutto $\in (0,5226-1)$ i zasiłki dla bezrobotnych $\in <0-0,4159>$ i nakłady inwestycyjne $\in (0,2850-1)$ i wpływ z podatku dochodowego od osób fizycznych $\in <0-0,6264>$ i przychody z całokształtu działalności $\in (0,2625-1)$ i koszty uzyskania przychodów z całokształtu działalności $\in (0,2280-1)$ i dochody budżetu państwa $\in (0,4167-1)$ i wydatki budżetu państwa $\in (0,3125-1)$ i wskaźnik cen produkcji sprzedanej przemysłu $\in <0-0,4054>$ i inflacja miesięczna $\in <0-0,3846>$ to wartość produkcji sprzedanej przemysłu $\in (0,66-1)$.

Na rysunku 2 przedstawiono schemat opracowanego przy pomocy zbiorów przybliżonych modelu produkcji sprzedanej przemysłu.



Rys. 2. Schemat modelu otrzymanego przy użyciu zbiorów przybliżonych

Źródło: Opracowanie własne.

Jak widać z przeprowadzonego wyżej badania, zbiory przybliżone pozwalają nie tylko na określenie, które ze zmiennych istotnie wpływają na badane zjawisko, ale również na konstrukcję reguł opisujących zależności między zmiennymi występującymi w badanym systemie informacyjnym. Dodatkową zaletą zbiorów przybliżonych jest to, że wyznaczone reguły posiadają swoją interpretację ekonomiczną oraz że można je przedstawić w formie lingwistycznej.

5. Wnioski z przeprowadzonych badań

Przedstawione w niniejszym artykule badania koncentrowały się na analizie stosowalności wybranych metod sztucznej inteligencji tj. sztucznych sieci neuronowych RBF, algorytmów genetycznych oraz teorii zbiorów przybliżonych, do modelowania *produkcji sprzedanej przemysłu*. Dodatkowo wszystkie otrzymane przy pomocy metod sztucznej inteligencji modele porównano z ekonometrycznym modelem *produkcji sprzedanej przemysłu*. Szczegółowy opis budowy modelu ekonometrycznego oraz wszystkich przeprowadzonych badań można znaleźć w [10].

pośród wszystkich modeli, zbudowanych przy użyciu różnych metod sztucznej inteligencji, modelem mającym najmniejszy błąd okazał się model RBF sprawdzający wszystkie możliwe kombinacje zmiennych objaśniających. Jednak z powodu zbyt długiego czasu oczekiwania na wyniki modelowania metoda ta jest metodą mało praktyczną. Metodą pozwalającą osiągnąć podobny rezultat modelowania (tzn. niewiele wyższy błąd *MSE* modelu), przy wielokrotnie krótszym czasie pracy komputera, jest metoda łącząca algorytm genetyczny z siecią RBF.

Poniżej zestawiono błędy wszystkich skonstruowanych modeli oraz zestawy zmiennych wybranych w trakcie modelowania przy użyciu poszczególnych metod (tabela 2).

Tabela 2. Zestawienie wyników efektów identyfikacji

Rodzaj modelu	Błąd modelu	Wybrane zmienne
RBF	0,0496	X ₁ , X ₄ , X ₅ , X ₉ , X ₁₆ , X ₁₈ , X ₁₉ , X ₂₀ , X ₂₂ , X ₂₄
Alg. genetyczny + RBF	0,0553	X ₁ , X ₄ , X ₅ , X ₇ , X ₉ , X ₁₄ , X ₁₆ , X ₁₇ , X ₂₀ , X ₂₂
Zbiory przybliżone	0,0663	X ₁ , X ₄ , X ₆ , X ₇ , X ₉ , X ₁₁ , X ₁₅ , X ₁₆ , X ₁₈ , X ₁₉ , X ₂₀ , X ₂₂
Model ekonometryczny	0,0722	X ₁ , X ₂ , X ₄ , X ₁₃ , X ₁₆ , X ₂₃

Legenda:

X1 Eksport towarów ogółem	X15 Przychody z całokształtu działalności
X4 Przeciętne wynagrodzenie nominalne brutto	X16 Koszty uzyskania przychodów
X5 Pracujący w sektorze przedsiębiorstw ogółem	X17 Wynik budżetu państwa ogółem
X6 Bezrobotni zarejestrowani ogółem	X18 Dochody budżetu państwa
X7 Zasiłki dla bezrobotnych	X19 Wydatki budżetu państwa
X9 Nakłady inwestycyjne	X20 Wskaźnik cen produkcji
X11 Wpływy z podatku dochodowego od osób fizycznych	X22 Inflacja miesięczna
X13 Należności	Wskaźnik cen towarów i usług konsumpcyjnych
X14 Kurs dolara	X24 Liczba ludności

Źródło: Opracowanie własne.

Po przeanalizowaniu tabeli 1 stwierdzono, że zmiennymi, które pojawiły się we wszystkich modelach były: *eksport towarów ogółem, przeciętne wynagrodzenie nominalne brutto, nakłady inwestycyjne, koszty uzyskania przychodów z całokształtu działalności, wskaźnik cen produkcji sprzedanej przemysłu oraz inflacja miesięczna*. Są to więc te zmienne, które w bardzo dużym stopniu wpływają na wielkość *produkcji sprzedanej przemysłu*.

Na podstawie przeprowadzonych badań oraz dokonanego przeglądu literatury porównano wady i zalety stosowania metod klasycznych oraz metod sztucznej na poszczególnych etapach modelowania. Tabela nr 3 przedstawia fragment dokonanego porównania (pełne porównanie zastosowanych metod można znaleźć w [10]).

Tabela 3. Fragment zestawienia przedstawiającego wady i zalety stosowania metod klasycznych oraz metod sztucznej inteligencji na poszczególnych etapach modelowania

Etap II	Metody klasyczne	Metody sztucznej inteligencji
opis:	Konstrukcja modelu	
wady:	- zwykle trudno jest znaleźć postać równania, które równocześnie spełnia kryteria merytoryczne doboru zmiennych z równoczesną formalną estymacją zgodności (np. z rozkładem normalnym) [3] [4].	- w przypadku stosowania sieci MLP i RBF nie można zapisać matematycznie postaci szacowanej funkcji [8] [11], - istotny jest czynnik czasu, jaki można poświęcić na proces uczenia sieci neuronowej [7] [9] [11], - możliwość przeuczenia lub niedouczenia sieci neuronowej [7] [11].
zalety:	- jeżeli rozkład danych rzeczywistych jest zgodny z założonym rozkładem, możliwe jest łatwiejsze dobranie struktury modelu, jak również jego skonstruowanie [5].	- nie wymaga się, aby relacja między zmienną zależną a zmiennymi niezależnymi była liniowa, nie musi być również znana natura nieliniowości [11].

Źródło: Opracowanie własne.

6. Uwagi końcowe

Niezwykle szybki rozwój cywilizacji, postępu technicznego oraz gospodarki światowej powoduje, że otaczająca człowieka rzeczywistość staje się coraz bardziej złożona. Szczególnie złożoną, a co za tym idzie, trudną do opisania, jest rzeczywistość ekonomiczna. Związane jest to przede wszystkim z istnieniem różnego rodzaju, wzajemnych powiązań między czynnikami mającymi wpływ na badane zjawisko ekonomiczne. Poznanie tych wzajemnych, często bardzo skomplikowanych i trudnych do zdefiniowania zależności wymaga zastosowania nowych rozwiązań. W związku z tym stale poszukuje się nowych metod modelowania zjawisk ekonomicznych, dzięki którym, w sposób jeszcze bardziej precyzyjny można będzie badane zjawiska opisać.

W ciągu ostatnich dekad obserwuje się ożywiony rozwój badań nad możliwościami stosowania metod sztucznej inteligencji w różnych dziedzinach życia. Prowadzone badania mają charakter interdyscyplinarny i stanowią przedmiot zainteresowań wielu dziedzin nauki. Zainteresowanie to jest wynikiem zmian jakie zachodzą w otaczającej nas rzeczywistości. Z kolei istotnym elementem procesu poznawania rzeczywistości jest analiza danych. Ze względu na różnorodność tych danych i charakteryzującą je niepewność i nieostrość, kluczowego znaczenia nabiera problem wyboru właściwych metod ich analizy.

Przedstawione w niniejszym artykule badania koncentrowały się na analizie stosowalności metod sztucznej inteligencji do modelowania produkcji sprzedanej przemysłu. Stosowane metody często nie są w stanie w pełni odzwierciedlić złożonej rzeczywistości ekonomicznej. Dzieje się tak, w przypadku gdy, nie dysponuje się pełnym zbiorem danych empirycznych, gdy dane są złej jakości, gdy nie dysponuje się wystarczająco dużą próbą lub gdy dane wyrażone są wyłącznie lub częściowo w formie lingwistycznej. Różnorodność i uniwersalność metod sztucznej inteligencji sprawia, że mogą być stosowane tam gdzie tradycyjne metody zawodzą.

Otrzymane wyniki przeprowadzonych przez autorkę badań dostarczyły dostatecznie wielu dowodów, aby stwierdzić, że opisane w artykule metody sztucznej inteligencji mogą być z powodzeniem stosowane w praktyce jako skuteczne narzędzie modelowania zjawisk ekonomicznych.

Bibliografia

- [1] Arabas J., (2001) Wykłady z algorytmów ewolucyjnych, Wydawnictwo Naukowo-Techniczne, Warszawa.
- [2] Goldberg D. E., (1998) Algorytmy genetyczne i ich zastosowania, Wydawnictwo Naukowo-Techniczne, Warszawa.
- [3] Goryl A., Jędrzejczyk Z., Kukula K., Osiewalski J., Walkosz A., *Wprowadzenie do ekonometrii w przykładach i zadaniach*, PWN, Warszawa 1996.
- [4] Gruszczynski M., Podgórska M., *Ekonometria*, Szkoła Główna Handlowa – Oficyna Wydawnicza, Warszawa 2004.
- [5] Hozer J. i in., (2005) Ekonometria stosowana z zadaniami, Katedra Ekonometrii i Statystyki Uniwersytetu Szczecińskiego, Szczecin.
- [6] Nowak E., (1984) Problemy doboru zmiennych do modelu ekonometrycznego, PWN, Warszawa.
- [7] Osowski S., (1996) Sieci neuronowe w ujęciu algorytmicznym, Wydawnictwo Naukowo-Techniczne, Warszawa.
- [8] Piegat A., (1999) Modelowanie i sterowanie rozmyte, Akademicka Oficyna Wydawnicza EXIT, Warszawa.
- [9] Rutkowski L., (2005) Metody i techniki sztucznej inteligencji, PWN, Warszawa.
- [10] Wąsikowska B., (2007) Niestandardowe metody identyfikacji czynników determinujących produkcję sprzedaną przemysłu, praca doktorska, Szczecin.
- [11] Witkowska D., *Sztuczne sieci neuronowe w analizach ekonomicznych*, Wydawnictwo Menadżer, Łódź 2000.

MODELS OF SOLD PRODUCTION OF INDUSTRY IN TERMS OF ARTIFICIAL INTELLIGENCE METHODS

Summary

In recent years increased interest in artificial intelligence methods is observed in such domains as: finance, medicine, engineering applications, geology or physics. In economy science these methods are exerted in bankruptcy forecasting, enterprise classification, exchange and share quotation forecasting, real estate appraisal and in credit rating. Nowadays a lot of revered scientific-research centers around the world are concerned with applications of artificial intelligence methods. The most important of them are: neural networks, fuzzy logic, genetic algorithms and rough set theory. These methods (especially neural networks and genetic algorithms) enable to automate some of the modeling process stages, what can in considerable measure facilitate building a model of particular economic phenomenon.

Keywords: artificial intelligence, radial basis networks, genetic algorithms, rough set theory, economic phenomena modeling.

Barbara Wąsikowska
Wydział Nauk Ekonomicznych i Zarządzania
Uniwersytet Szczeciński
ul. Mickiewicza 64, 71-101 Szczecin
e-mail: barbara.wasikowska@wneiz.pl