

Krzysztof JURCZYK\*

## ZASTOSOWANIE SZTUCZNYCH SIECI NEURONOWYCH JAKO NARZĘDZIA WSPOMAGAJĄCEGO ZARZĄDZANIE ZAPASAMI I PLANOWANIE POPYTU NA PRZYKŁADZIE PRZEDSIĘBIORSTWA DYSTRYBUCYJNEGO

### Streszczenie

Celem niniejszej pracy było wykazanie możliwości zastosowania metod sztucznej inteligencji, a w szczególności sztucznych sieci neuronowych do prognozowania popytu w centrum dystrybucyjnym firmy IMI International sp. z o. o. w Olewinie. Wyniki uzyskane z zastosowania utworzonego modelu porównano z wynikami osiąganymi przy użyciu klasycznych metod prognozowania.

**Słowa kluczowe:** prognozowanie, sztuczne sieci neuronowe, zarządzanie zapasami

### 1. WPROWADZENIE

Jednym z powszechnych problemów występujących w przedsiębiorstwach jest efektywne zarządzanie zaopatrzeniem. Decyzje planistyczne dotyczące tego obszaru działania dotyczą w głównej mierze umiejętnego zarządzania zapasami, tzn. takiego, dzięki któremu można uniknąć nadmiernych stanów magazynowych, a jednocześnie zapewnić odpowiedni poziom obsługi klienta.

Minimalizacja poziomu zapasów pozwala ograniczyć koszty ich utrzymania. Wysokie stany magazynowe z kolei gwarantują wysoki poziom obsługi klienta. Te dwa stwierdzenia pozwalają wysnuć wniosek, że dobór odpowiedniej strategii sterowania zapasami ma swoje źródło w profilu popytu jaki jest na te zapasy zgłaszany ze strony rynku.

Poprawne zbadanie profilu popytu oraz ustalenie na tej podstawie wiarygodnych prognoz pozwoli przede wszystkim ograniczyć koszty gromadzenia zapasów. Wiarygodne prognozy pozwolą na dynamiczne dostosowywanie poziomu zapasów do wymagań rynku oraz zwiększenie ich rotacji. To z kolei pozwoli na zwiększenie płynności finansowej przedsiębiorstwa.

### 2. PREZENTACJA FIRMY IMI INTERNATIONAL

IMI International sp. z o.o. z siedzibą w Olewinie koło Krakowa jest polskim oddziałem IMI International, będącej organizacją handlową dla marek HEIMEIER, TA i PNEUMATEX w Europie Środkowej i Wschodniej. Firma w Polsce została założona w 1993 roku. Centrum logistyczne obsługuje ponad 20 krajów (rysunek 1), z magazynu o powierzchni paru tysięcy metrów kwadratowych, gdzie na 6500 miejscach paletowych znajduje się około 3500 pozycji asortymentowych. Firma ma ambicje, wiedzę i możliwości aby być liderem w zakresie rozwiązań dla doskonałego klimatu wewnętrznego, kontroli temperatury i równoważenia hydraulicznego instalacji.[6]

---

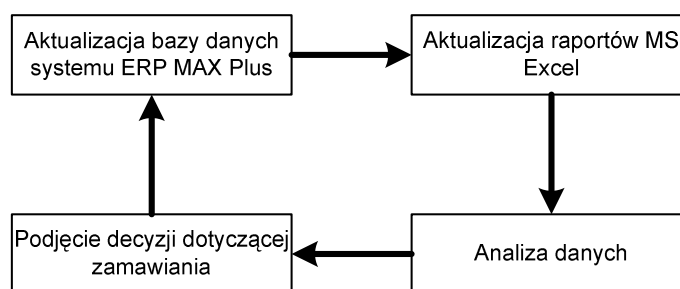
\* Akademia Górniczo-Hutnicza, Wydział Zarządzania



Rys. 1. Obszary działania firmy IMI International  
 Źródło: Materiały własne firmy IMI International sp. z o. o.

### 3. ZARZĄDZANIE ZAPASAMI W PRZEDSIĘBIORSTWIE

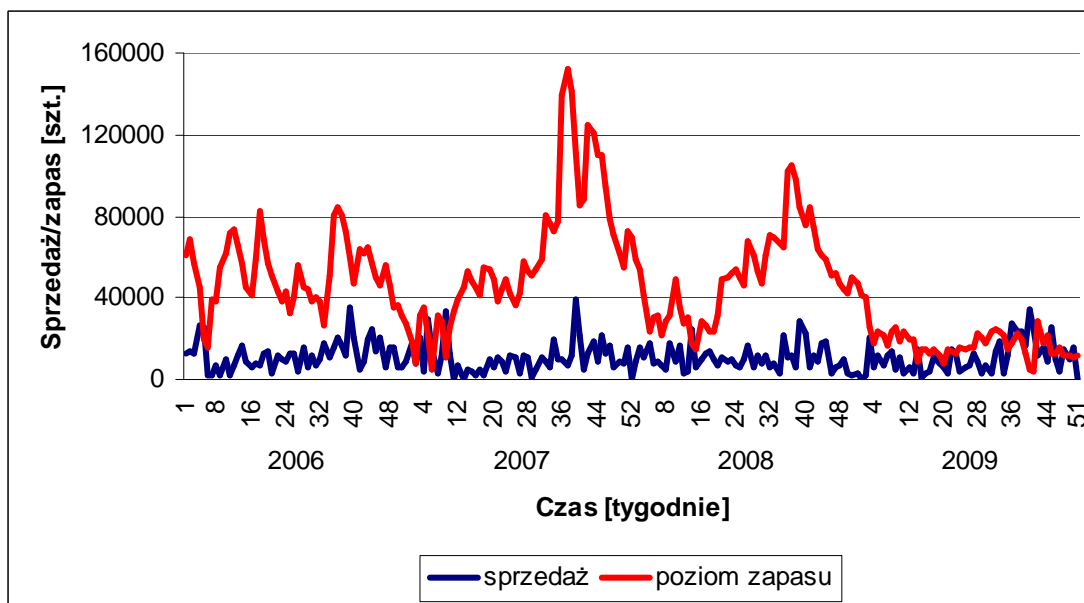
Uproszczony schemat zarządzania zapasami w przedsiębiorstwie IMI International sp. z o. o. zamieszczono na rysunku 2.



Rys. 2. Uproszczony schemat działania systemu zarządzania zapasami w IMI International sp. z o. o.  
 Źródło: opracowanie własne

Wszystkie dane związane z przepływami produktów w przedsiębiorstwie i zawarte w systemie ERP MAX Plus są eksportowane na bieżąco do raportów programu MS Excel. Analiza takich raportów pozwala kierownictwu podjąć decyzję zamawiania bądź nie danego produktu.

W raporcie takim w kolejnych kolumnach można znaleźć m. in. dane dotyczące sprzedaży danego produktu za ostatnie 12 miesięcy, planowaną sprzedaż na miesiąc obecny (obliczaną jako iloczyn średniej sprzedaży za ostatnie 11 miesięcy i ustalonych wskaźników sezonowości dla danego produktu), poziom zapasu półkowego, informacje na temat alokacji, dostaw, zamówień oraz co najważniejsze poziom zapasu rekomendowanego. Zapas rekomendowany obliczany jest na podstawie planowanej sprzedaży na dany miesiąc oraz w oparciu o decyzje zarządu dotyczące kwestii jaki okres czasu ma ten zapas pokryć (przykładowo dwutygodniowy zapas rekomendowany przy prognozie sprzedaży 500 sztuk wyniesie 250 sztuk danego produktu). Na podstawie raportów MS Excel podejmowane są również decyzje o przypisaniu produktów do grup asortymentowych wg klasyfikacji ABC.



**Rys. 3. Poziom sprzedaży i poziom zapasu głowicy termostatycznej typu K w latach 2006–2009**  
*Źródło: opracowanie własne na podstawie danych firmy IMI International sp. z o. o.*

Docelowa polityka zarządzania zapasami w przedsiębiorstwie zakładała zapewnienie wysokiego poziomu obsługi klienta dla produktów należących do grupy A oraz stosowanie strategii „partia na partię” dla grupy C. Mimo tych założeń zarządzanie zapasami w oparciu o prosty model zbudowany na bazie raportów MS Excel skutkowało jednak podejmowaniem błędnych decyzji zakupowych. W rezultacie utrzymywano nieuzasadnione, zbyt wysokie stany magazynowe jak pokazano na rysunku 3 (przykład dotyczy głowicy termostatycznej typu K – rysunek 4).

Warto nadmienić, że współczynnik korelacji między poziomem sprzedaży a poziomem zapasów wynosił w przedstawionym okresie zaledwie 0,05.



**Rys. 4. Głowica termostatyczna typu K**

*Źródło: <http://www.imi-internationalcee.com/pl/pic/950> [data dostępu: 13 stycznia 2010 r.]*

Osiągnięty wolumen sprzedaży dodatkowo utrudniał podejmowanie odpowiednich decyzji dotyczących sterowania zapasami – proste analizy prowadzone w MS Excel stały się zbyt uciążliwe i czasochłonne. W pewnym momencie kierownictwo zdecydowało się na zakup nowego systemu, który miał to usprawnić. Wybór padł na narzędzie informatyczne o nazwie Analizator i Sugestator Zapasów – AiSZ.


## 4. PROGNOZOWANIE Z WYKORZYSTANIEM SYSTEMU AISZ

System AiSZ jak sama nazwa wskazuje zbudowany jest z dwóch modułów, które można zlokalizować po wczytaniu strony startowej systemu. Pierwszym z dostępnych modułów jest moduł Analizatora, drugim moduł Sugestatora. Dostawcą systemu AiSZ jest Ośrodek Nowoczesnych Techniek Zarządzania sp. z o.o. z siedzibą w Poznaniu.

Moduł Sugestatora przy obliczaniu wielkości partii uzupełniających kieruje się następującymi metodami:


- Metoda wskaźnikowa,
- Model Browna.
- Model Holta,
- Model addytywny Wintera,
- Model multiplikatywny Wintera.

Kształtowanie się prognoz popytu na głowicę termostatyczną typu K według każdej z przedstawionych powyżej metod przedstawiono graficznie na rysunkach 5-9.




**Rys. 5. Prognozy popytu na głowicę termostatyczną typu K w okresie od 18 maja 2009 r. do 21 maja 2010 r. wg modelu addytywnego Wintera**

*Źródło: Opracowanie własne na podstawie danych firmy IMI International sp. z o. o.*




**Rys. 6. Prognozy popytu na głowicę termostatyczną typu K w okresie od 18 maja 2009 r. do 21 maja 2010 r. wg modelu multiplikatywnego Wintera**

*Źródło: Opracowanie własne na podstawie danych firmy IMI International sp. z o. o.*




**Rys. 7. Prognozy popytu na głowicę termostatyczną typu K w okresie od 18 maja 2009 r. do 21 maja 2010 r. wg modelu Holta**

*Źródło: Opracowanie własne na podstawie danych firmy IMI International sp. z o. o.*



**Rys. 8. Prognozy popytu na głowicę termostatyczną typu K w okresie od 18 maja 2009 r. do 21 maja 2010 r. wg modelu Browna**

*Źródło: Opracowanie własne na podstawie danych firmy IMI International sp. z o. o.*



**Rys. 9. Prognozy popytu na głowicę termostatyczną typu K w okresie od 18 maja 2009 r. do 21 maja 2010 r. wg metody wskaźnikowej**

*Źródło: Opracowanie własne na podstawie danych firmy IMI International sp. z o. o.*

Wartości błędów dla prognoz popytu na głowicę termostatyczną typu K według przedstawionych wcześniej klasycznych metod prognozowania zamieszczono w tabeli 1.

Tablica 1. Porównanie wartości błędów uzyskanych przy prognozowaniu popytu metodami klasycznymi

Metoda prognozowania	Wartość błędu				
	ME	MAE	MSE	MPE	MAPE
Model Browna	1,11E+03	9,47E+03	1,84E+08	-229 %	266 %
Model Holta	1,19E+02	9,89E+03	1,98E+08	-246 %	281 %
Model addytywny Wintera	-3,08E+02	1,07E+04	2,26E+08	-263 %	302 %
Model multiplikatywny Wintera	-4,12E+04	4,73E+04	3,37E+09	-1 399 %	1 445 %
Metoda wskaźnikowa	2,57E+03	6,02E+03	1,19E+08	-117 %	154 %

Źródło: Opracowanie własne

Porównując otrzymane wyniki można stwierdzić, że system AiSZ nie będzie przydatnym narzędziem zarządzania zapasami w przedsiębiorstwie IMI International sp. z o. o. w Olewinie. Prognozy popytu ustalane w module Sugestatora tego systemu są obciążone zbyt dużym błędem. Nawet „najlepsze” rozwiązanie uzyskane przy prognozowaniu popytu metodą wskaźnikową nie daje zadowalających i wiarygodnych prognoz, na podstawie których można by ustalić odpowiednią politykę zarządzania zapasami w przedsiębiorstwie. Ponadto kolejnym czynnikiem dyskwalifikującym system AiSZ okazują się błędy towarzyszące jego implementacji w przedsiębiorstwie IMI International sp. z o. o. [1]

Brak praktycznej możliwości zastosowania systemu AiSZ do zarządzania zapasami w przedsiębiorstwie IMI International sp. z o. o. skłania do poszukiwania nowego – lepszego – rozwiązania problemu. Inspiracją do wyboru metody były efekty korzystania z modeli zbudowanych w oparciu o logikę rozmytą [5] i algorytmy genetyczne [4]. W rozwiązaniu problemu dotyczącego firmy IMI wykorzystano sztuczne sieci neuronowe.

## 5. MODEL PROGNOZOWANIA POPYTU OPARTY O SSN

Zestawienie wielkości wejściowych oraz wyjściowych zaproponowanego modelu zestawiono w tabeli 2.

Tablica 2. Wielkości wejściowe i wyjściowe rozpatrywanego modelu neuronowego

Zmienne wejściowe:	
$x_1$	– kod tygodnia
$x_2$	– wartość sprzedaży produktów marki HEIMEIER w danym tygodniu
$x_3$	– wartość sprzedaży produktów marki HEIMEIER należących do grupy A wg klasyfikacji ABC w danym tygodniu
$x_4$	– wartość sprzedaży wszystkich produktów w danym tygodniu
$x_5$	– całkowite zapotrzebowanie magazynów krajowych w okresie $t - 1$
$x_6$	– średnia wielkość sprzedaży głowicy termostatycznej typu K. w okresach od $t - 1$ do $t - 2$ ,
$x_7$	– średnia wielkość sprzedaży głowicy termostatycznej typu K. w okresach od $t - 1$ do $t - 3$ ,
$x_8$	– średnia wielkość sprzedaży głowicy termostatycznej typu K. w okresach od $t - 1$ do $t - 4$ ,
Zmienna wyjściowa:	
$y$	– wielkość sprzedaży głowicy termostatycznej typu K w okresie $t$ ,

Źródło: Opracowanie własne

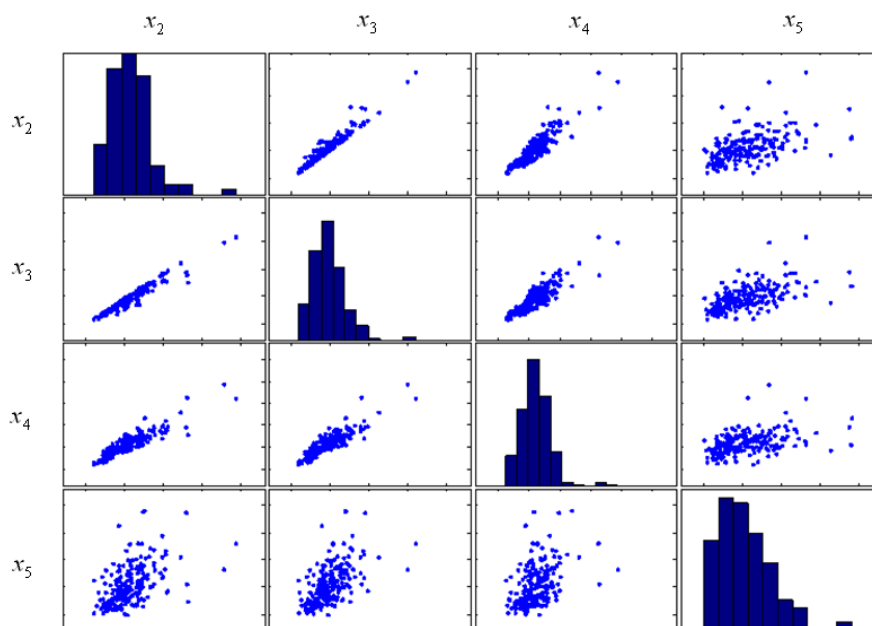
Poziom sprzedaży poszczególnych produktów w głównej mierze zależy od zapotrzebowania jakie wcześniej zgłaszają magazyny lokalne w poszczególnych krajach Europy Wschodniej i Środkowej. Ponadto analiza wykazała, że sprzedaż głowicy termostatycznej typu K w tygodniu  $t$ , będzie zależeć od poziomu sprzedaży wszystkich produktów marki HEIMEIER, a w szczególności tych, które wg klasyfikacji ABC należą do grupy asortymentowej A. W badaniach uwzględniono również całkowitą tygodniową wartość sprzedaży wszystkich pozycji asortymentowych oferowanych przez centrum dystrybucyjne IMI International sp. z o. o., kod tygodnia oraz średnie wielkości sprzedaży głowicy termostatycznej typu K w trakcie dwóch, trzech oraz czterech wcześniejszych tygodni. Zależności między poszczególnymi zmiennymi wejściowymi oraz zmienną wyjściową  $y$ , przedstawione zostały w tabeli 3.

**Tabela 3. Wartości współczynników korelacji liniowej pomiędzy poszczególnymi zmiennymi modelu**

	$y$	$x_1$	$x_2$	$x_3$	$x_4$	$x_5$	$x_6$	$x_7$	$x_8$
$y$	1	0,118	0,698	0,750	0,596	0,790	0,158	0,190	0,241
$x_1$		1	0,196	0,212	0,238	0,114	0,226	0,300	0,348
$x_2$			1	0,963	0,887	0,494	0,086	0,114	0,148
$x_3$				1	0,875	0,555	0,094	0,128	0,173
$x_4$					1	0,416	0,212	0,217	0,217
$x_5$						1	0,171	0,215	0,252
$x_6$							1	0,867	0,768
$x_7$								1	0,913
$x_8$									1

Źródło: Opracowanie własne


Ponadto zależności między najistotniejszymi zmiennymi pokazano na rysunku 10.



**Rys. 10. Macierzowy wykres rozrzutu zależności między wybranymi zmiennymi wejściowymi utworzonego modelu**

Źródło: Opracowanie własne

Strukturę sieci jednokierunkowej, zbudowanej w oparciu o powyższe dane zaprezentowano na rysunku 11.




**Rys. 11. Architektura zaproponowanego modelu neuronowego**  
Źródło: Opracowanie własne

Zaproponowana sieć trójwarstwowa, o liczbie  $n = 4$  neuronów ukrytych została utworzona przy użyciu pakietu MATLAB. Wyboru takiej struktury dokonano na podstawie metody prób i błędów testowania różnych struktur o liczbie neuronów ukrytych zawierającej się w przedziale od 1 do 10. Proces uczenia sieci poprzedził etap normalizacji danych, której dokonano względem wartości minimalnej.

Do uczenia sieci zostało użytych 206 przypadków pochodzących z okresu od 5 września 2005 r. do 31 grudnia 2009 r. Zbiór danych podzielono na podzbiory: uczący, walidacyjny oraz testujący odpowiednio w stosunku: 60 % – 20 % – 20 %. Podziału dokonano w sposób losowy.

Jako podstawowym kryterium oceny jakości modelu wybrano wartość błędu średniokwadratowego MSE. Na rysunku 12 zamieszczono przebieg funkcji błędów uczenia analizowanej sieci wg algorytmu Levenberga-Marquardta.



**Rys. 12. Wykres błędów uczenia sieci dla zbioru uczącego, walidacyjnego oraz testującego (wartości dla danych znormalizowanych)**

Źródło: Opracowanie własne



Proces uczenia sieci założono na 50 epok. Proces ten nie został wcześniej przerwany, gdyż błąd walidacji osiągnął najniższą wartość dopiero w ostatniej epoce.

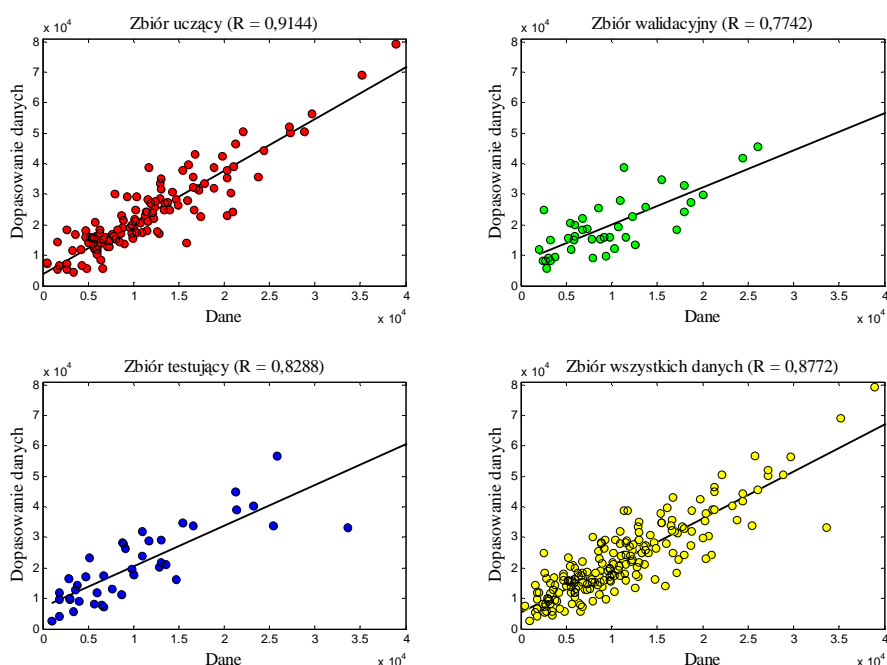
W tabeli 4 zamieszczono porównanie błędów MSE rozważanej sieci neuronowej dla różnych testowanych algorytmów uczenia. Algorytmy te wybrano jako przykładowe z tych, które są dostępne w pakiecie MATLAB.

**Tablica 4. Porównanie błędów MSE zbudowanej sieci neuronowej dla różnych algorytmów uczenia**

Algorytm	Nazwa algorytmu uczenia	Błąd uczenia	Błąd walidacji	Błąd testowania
trainlm	Levenberg-Marquardt	4,29E+03	6,27E+03	6,08E+03
trainbfg	Quasi-Newton backpropagation	4,41E+03	5,45E+03	6,70E+03
trainscg	Scaled conjugate gradient backpropagation	5,13E+03	5,64E+03	5,26E+03
traincgf	Fletcher-Powell conjugate gradient backpropagation	4,90E+03	5,87E+03	5,61E+03
trainoss	One step secant backpropagation	4,95E+03	5,43E+03	6,57E+03
traincgp	Polak-Ribière conjugate gradient backpropagation	5,10E+03	5,14E+03	5,50E+03

Źródło: Opracowanie własne

Jak można zauważyć najniższą wartość błędu MSE dla zbioru uczącego uzyskano przy zastosowaniu algorytmu Quasi-Newton backpropagation. Mimo to w dalszych analizach omówiono sieć wykorzystującą algorytm Levenberga-Marquardta. Powodem wyboru tego algorytmu były wyniki uzyskane podczas kolejnego etapu analizy jakości sieci.



**Rys. 13. Analiza jakości sieci metodą regresji liniowej**

Źródło: Opracowanie własne

Kolejnym etapem analizy jakości sieci było zbadanie regresji liniowej między uzyskanymi wynikami a wartościami docelowymi. Analiza została przeprowadzona zarówno w stosunku do całego zbioru danych, jak i dla podzbiorów: uczącego, walidacyjnego oraz testującego. Wyniki zobrazowano rysunkiem 13.

Zestawienie danych statystycznych przeprowadzonej analizy metodą regresji liniowej zamieszczono w tabeli 5.

**Tabela 5. Dane statystyczne regresji liniowej**


Statystyka	Zbiór uczący	Zbiór walidacyjny	Zbiór testujący	Zbiór wszystkich danych
Średnia z danych MD	2,34E+04	1,94E+04	2,08E+04	2,21E+04
Odchylenie standardowe danych SDD	1,32E+04	9,60E+03	1,23E+04	1,24E+04
Średni błąd ME	1,22E+01	-1,76E+01	1,87E+02	4,10E+01
Odchylenie standardowe błędu SDE	5,85E+03	8,67E+03	7,81E+03	6,87E+03
Stosunek SDE/SDD	0,44	0,90	0,64	0,55
Korelacja R	0,91	0,77	0,83	0,88

Źródło: Opracowanie własne

Najistotniejszym z przedstawionych wskaźników oceny regresji liniowej jest stosunek odchylenia standardowego błędów SDE do odchylenia standardowego danych SDD. Wartości tego wskaźnika przyjmują bardzo wysokie wartości, co świadczy o niezbyt dobrych zdolnościach regresyjnych sieci. Można przyjąć nawet, że wartości te dyskwalifikują utworzony model [3]. Otrzymane rezultaty sprawiają, że pojawia się pytanie o użyteczność stworzonej sieci neuronowej.

## 6. PORÓWNANIE ZBUDOWANEGO MODELU Z METODAMI KLASYCZNYMI

Na rysunku 14 przedstawiono kształtowanie się prognoz sprzedaży głowicy termostaticznej typu K wg zbudowanego modelu neuronowego. Wyniki skonfrontowano z tymi, jakie na podstawie metody wskaźnikowej dostarcza system AiSZ (tabela 6).



**Rys. 14. Prognozy sprzedaży głowicy termostaticznej typu K. w okresie od 28 września 2009 r. do 21 maja 2010 r. wg metody wskaźnikowej oraz modelu neuronowego**

Źródło: Opracowanie własne

**Tablica 6. Porównanie wartości błędów MPE i MAPE uzyskanych przy prognozowaniu popytu metodą wskaźnikową oraz przy użyciu modelu SSN**

Metoda prognozowania	Wartość błędu	
	MPE	MAPE
Model SSN	-50 %	86 %
Metoda wskaźnikowa	-229 %	251 %

*Źródło: Opracowanie własne*

Badania symulacyjne wykazały [2], że model neuronowy pozwala na uzyskanie trzykrotnie lepszych wyników w stosunku do tych, które daje metoda wskaźnikowa (mimo faktu, że uzyskane wartości błędów nadal znajdują się na poziomie nie do zaakceptowania). Można przypuszczać, że zbudowane w oparciu o neuronowy model prognozowania zapotrzebowania modele zarządzania zapasami pozwolą uzyskać lepsze rezultaty niż modele budowane na bazie klasycznych metod prognozowania.

## 7. PODSUMOWANIE I WNIOSKI

Struktura asortymentu, częstotliwość dostaw, czas realizacji zamówień, warunki magazynowania, organizacja i struktura kanałów dystrybucji oraz rodzaj zużycia (zapotrzebowania) – te czynniki wpływają na wybór odpowiedniej metody sterowania zapasami.

Budowa odpowiedniego systemu zarządzania zapasami wymaga uwzględnienia wszystkich wymienionych wcześniej elementów. W niniejszej pracy przedstawiono model analizy tylko jednego z nich – był to model prognozowania zapotrzebowania przy użyciu sztucznych sieci neuronowych.

O wyborze tej składowej systemu zarządzania zapasami zdecydował dostęp autora do danych sprzedaży centrum dystrybucyjnego IMI International sp. z o. o. w Olewinie. Niestety brak dostępu do szczegółowych danych sprzedaży magazynów lokalnych sprawił, że dane, których użyto w badaniach mogły okazać się niewystarczającymi, co z kolei miało bezpośredni wpływ na uzyskane wyniki.

Zbudowany model pozwolił osiągnąć dużo lepsze rezultaty (prognozy obarczone mniejszą wartością błędu) niż metody klasyczne. Wyniki jakie uzyskano sprawiają jednak, że problem ustalania wiarygodnych prognoz sprzedaży w firmie IMI International sp. z o. o. nadal pozostaje sprawą otwartą.

Na podstawie wyników symulacji dokonanych na zbudowanym modelu można jednak stwierdzić, że sztuczne sieci neuronowe mają ogromne zastosowanie w prognozowaniu zjawisk gospodarczych i z reguły dają lepsze rezultaty niż metody klasyczne. Czynnikiem ten zachęca do dalszych badań i analiz problemu zarządzania zapasami w przedsiębiorstwie IMI International sp. z o. o. w Olewinie. Analiza wszystkich wymienionych na wstępie elementów składowych systemu prawdopodobnie pozwoli na budowę odpowiedniego systemu sterowania zapasami w przedsiębiorstwie.

## LITERATURA

- [1] Jurczyk K., *Analiza systemu zarządzania zapasami na przykładzie Centrum Dystrybucyjnego IMI International sp. z o. o. w Olewinie*, Translogistics 2009: Zbiór prac prezentowanych podczas V Ogólnopolskiego Forum Studentów Transportu i Logistyki, Oficyna Wydawnicza Politechniki Wrocławskiej, Wrocław 2009, s. 111–118
- [2] Jurczyk K., *Zarządzanie zapasami i analiza profilu popytu z wykorzystaniem sztucznych sieci neuronowych na przykładzie IMI International sp. z o. o.*, Praca magisterska, Wydział Zarządzania AGH, Kraków 2010
- [3] Karkula M., *Modelowanie i symulacja złożonych procesów logistycznych o charakterze dyskretno-ciągłym na przykładzie Elektrociepłowni Kraków SA*, Rozprawa doktorska, Wydział Zarządzania AGH, Kraków 2007
- [4] Radhakirshnan P., Prasad V.M., Gopalan M.R.: *Inventory Optimization in Supply Chain Management using Genetic Algorithm*, IJCSNS International Journal of Computer Science and Network Security, VOL.9 No.1, January 2009, s. 33–40
- [5] Samanta B., Al-Araimi S.A., *An inventory control model using fuzzy logic*, International Journal of Production Economics 73 (2001), s. 217–226
- [6] [<http://www.imi-internationalcee.com/pl/>] *ostatni dostęp: 1 czerwca 2010 r.*

## INVENTORY OPTIMIZATION AND DEMAND PATTERN ANALYZIS USING ARTIFICIAL NEURAL NETWORKS ON THE EXAMPLE OF DISTRIBUTION ENTERPRISE

**Abstract**

In the paper, the analysis of the possibility of using artificial neural networks to forecast demand level at the IMI International was introduced. The results from using neural model were compared with the results of using classical forecasting methods.

**Keywords:** artificial neural networks, forecasting, inventory management