

# Analiza efektywności wykorzystania kryteriów informacyjnych w prognozowaniu zapotrzebowania na części zamienne

## Wprowadzenie

Istnieje wiele metod, narzędzi oraz programów wspomagających podejmowanie decyzji w zakresie prognozowania zapotrzebowania na materiały niezbędne do realizacji procesu produkcyjnego. Typowy proces produkcyjny cechuje powtarzalność i stosunkowo duża przewidywalność. Zarządzanie dużymi zasobami (materialnymi i niematerialnymi) w przedsiębiorstwie stanowi trudne wyzwanie dla kadry kierowniczej<sup>1</sup>. Zapotrzebowanie na określone materiały, półfabrykaty, podzespoły zostaje wyznaczone z wykorzystaniem systemów typu MRP, MRP II, ERP<sup>2</sup>. Istnieje jednak pewna część zasobów, które nie są bezpośrednio powiązane z procesem wytwarzania danego produktu, a mimo to determinują możliwość realizacji tego procesu. Są to wszelkiego rodzaju części zamienne, z których zbudowane są maszyny (np. obrabiarki) i urządzenia wykorzystywane w procesie produkcyjnym. Prognozowanie zapotrzebowania na części zamienne w przypadku stabilnych systemów produkcyjnych, w skład których wchodzi mało awaryjne maszyny (urządzenia), stanowi niewielki problem. Części zamienne niezbędne do naprawy danej maszyny zamawiane są rzadko, a regularnie przeprowadzane przeglądy gwarantują praktycznie bezawaryjną pracę. Jeśli jednak rozważyć proces produkcyjny, w którym ze względu na jego specyfikę maszyny ulegają awariom właściwie nieprzerwanie, wówczas kwestia efektywnego prognozowania zapotrzebowania na części zamienne urasta do rangi bardzo ważnego problemu.

Przykładem takiego procesu jest z całą pewnością proces wydobywczy. Jego specyfika różni się znacząco od typowego procesu wytwórczego. Maszyny niezbędne do realizacji takiego procesu są niestacjonar-

ne i znajdują się praktycznie w ciągłym ruchu. Warunki eksploatacji złoże są na ogół bardzo trudne — towarzyszy im duża wilgotność, zawodnienie, wysoka temperatura, nierówne drogi. W efekcie maszyny ulegają bardzo częstym awariom. W takim przedsiębiorstwie kwestia zapewnienia odpowiedniego zapasu części zamiennych jest właściwie równoważna z zabezpieczeniem należytej liczby kotew, czy np.

Tabela 1  
Potencjalne straty wynikające z niedoboru lub nadmiaru części zamiennych

| Potencjalne straty wynikające z braku części zamiennych   | Potencjalne straty wynikające z utrzymywania nadmiernych zapasów części <sup>3</sup>   |
|---|--|
| Wydłużenie czasu naprawy  | Koszty tworzenia zapasów   |
| Brak dyspozycyjności maszyny do pracy   | Koszty utrzymania zapasów — kapitałowe (zamrożenie kapitału)   |
| Zagrożenie niewykonania planu produkcyjnego z powodu niedostępności maszyny która uległa awarii | Koszty utrzymania zapasów — magazynowania (koszty powierzchni magazynowej: rzeczowe i osobowe związane z przeciętnym składowaniem i wydawaniem towaru) |
| Dezorganizacja pracy mechaników   | Koszty utrzymania zapasów — obsługi zapasów (wydatki związane z ubezpieczeniem zapasów)  |
| Dezorganizacja pracy operatora  | Koszty utrzymania zapasów — ryzyka (np. uszkodzenia zapasu podczas magazynowania)  |

Źródło: opracowanie własne.

materiałów strzałowych, czyli materiałów biorących bezpośredni udział w procesie wydobywania.

<sup>1</sup> J. Helman, *Model realizacji zamówienia z wykorzystaniem systemu planowania zasobów przedsiębiorstwa*, Gospodarka Materialowa i Logistyka 2012, nr 1, s. 18.

<sup>2</sup> E. Chlebus, *Techniki komputerowe CAx w inżynierii produkcji*, Wydawnictwa Naukowo-Techniczne, Warszawa 2000, s. 71–72.

<sup>3</sup> P. Kozik, J. Sęp, *Planowanie zapotrzebowania części zamiennych silnika lotniczego w prototypie informatycznego systemu DEL*, Zarządzanie Przedsiębiorstwem 2012, nr 4.

W pewnym przedsiębiorstwie z branży wydobywczej zaobserwowano, że czas napraw maszyn dołowych wynika w dużej mierze z braku dostępnych części zamiennych lub z powodu długiego oczekiwania na te części. Aby skrócić czas napraw poprzez zapewnienie niezbędnych części, należałoby zastosować efektywną metodę prognozowania zapotrzebowania, a następnie, wykorzystując jej wyniki — odpowiednio zamawiać części.

Gospodarka zasarami jest jednym z podstawowych elementów zarządzania przedsiębiorstwem<sup>4</sup>. Obecnie dążą one do tego, aby ilość zapasów materiałowych w przedsiębiorstwie była jak najniższa, ponieważ obniża to koszty magazynowania. Jednak należy zwrócić uwagę, że taka polityka firmy może prowadzić do wystąpienia innych problemów (strat), które mogą się pojawić, jeśli poziom zapasów jest zbyt niski. W tabeli 1 zaprezentowano zestawienie potencjalnych strat, jakie wywołwane są przez brak części zamiennych lub utrzymywanie ich nadmiernych zapasów.

W celu opracowania efektywnej metody prognozowania zapotrzebowania na części zamienne przeanalizowano zarówno klasyczne metody, jak i nowe podejścia wykorzystujące metody sztucznej inteligencji.

## Klasyczne metody prognozowania

Istnieje wiele metod pozwalających na prognozowanie popytu, ale tylko niektóre z nich znajdują zastosowanie w predykcji zapotrzebowania na części zamienne. Wartością podlegającą prognozie jest poziom zapotrzebowania na części. Należy podkreślić, że badając kształtowanie się procesu zapotrzebowania w czasie, można zauważyć pewne charakterystyczne cechy, takie jak brak powtarzalności, niestabilność, częste przyjmowanie wartości zerowych, losowość. W języku angielskim popyt o takiej charakterystyce określany jest mianem *lumpy demand*. W literaturze znaleźć można wiele metod pozwalających na prognozowanie zapotrzebowania na części zamienne. Do najbardziej znanych zaliczyć można metodę wygładzania wykładniczego (*Single Exponential Smoothing*, SES), metodę Browna, metodę Crostona CR, metodę Syntetosa-Boylana (*Syntetos-Boylan Approximation*, SBA), metodę średniej ruchomej (*Moving Average*, MA), metodę ważonej średniej ruchomej (*Weighted Moving Average*, WMA), model Holta, addytywny lub multiplikatywny model Wintersa, metodę Bootstrap, metodę Poissona, model predykcyjny Greya (*Grey prediction model*), metody ARMA, ARIMA, a także predykcję ekonometryczną.

Po wstępnej analizie efektywności wymienionych metod wybrano pięć, które stanowić będą kryte-

rium porównania dla przedstawionej w dalszej części pracy koncepcji prognozowania zapotrzebowania na części zamienne. W części artykułu poświęconej badaniom empirycznym wykorzystane zostaną metody średniej ruchomej MA, wygładzania wykładniczego SES, SBA, ARIMA oraz predykcja ekonometryczna.

Metoda średniej ruchomej MA wykorzystuje następujący wzór (1) na wartość prognozy  $F_t$  w okresie  $t$ :

$$F_t = MA(k) = \frac{F_{t-1} + F_{t-2} + \dots + F_{t-k}}{k}, \quad (1)$$

gdzie:

$k$  — liczba okresów,

$F_{t-k}$  — wartość prognozy w poprzednim okresie.

Metody wygładzania wykładniczego SES są uogólnieniem metod średnich ruchomych. Wartości wygładzonego szeregu czasowego są ważonymi sumami wartości z przeszłości. Konstruując prognozę przyjmuje się, że w miarę cofania się w przeszłość znaczenie obserwacji w określaniu bieżącej wygładzanej wartości zmiennej maleje. Celem zastosowania każdej z tych metod jest wykorzystanie wygładzonego szeregu do prognozowania<sup>5</sup>.

Metodą dedykowaną popytowi niestabilnemu jest metoda Crostona CR<sup>6</sup>. W tej metodzie stosowana jest reguła, że jeżeli w badanym okresie nie występuje popyt, to poziom zapotrzebowania nie jest zmieniany. Jeżeli natomiast wystąpi zapotrzebowanie ( $X_t > 0$ ), wówczas prognozy są aktualizowane według wzorów (2, 3):

$$Z_t = \alpha X_t + (1 - \alpha) Z_{t-1}, \quad (2)$$

$$P_t = \alpha G_t + (1 - \alpha) P_{t-1}, \quad (3)$$

gdzie:

$Z_t$  — wielkość zapotrzebowania w danym okresie,

$P_t$  — czas wystąpienia zapotrzebowania,

$X_t$  — aktualna wielkość zapotrzebowania w okresie  $t$ ,

$G_t$  — aktualny przedział czasowy pomiędzy kolejnymi transakcjami,

$\alpha$  — stała wygładzania.

Wartość prognozy  $F_{t+1}$  obliczana jest ze wzoru (4):

$$F_{t+1} = \frac{Z_t}{P_t}. \quad (4)$$

Ulepszenie tej metody zasugerowali A.A. Syntetos i J.E. Boylan (metoda SBA). Zaproponowali, aby wzór (5) na prognozę zapotrzebowania  $F_{t+1}$  przyjął postać<sup>7</sup>:

<sup>5</sup> M. Gruszczyński, T. Kuszewski, M. Podgórska, *Ekonometria i badania operacyjne*, Wydawnictwo Naukowe PWN, Warszawa 2009, s. 115.

<sup>6</sup> J.D. Croston, *Forecasting and Stock Control for Intermittent Demand*, *Operational Research Quarterly* 1972, 23 (3), s. 289–303.

<sup>7</sup> A.A. Syntetos, J.E. Boylan, *On the stock control performance of intermittent demand estimators*, *International Journal of Production Economics*, 103, s. 36–47.

<sup>4</sup> E. Kardas, *Prognozowanie produkcji jako czynnik kształtujący poziom zapasów w przedsiębiorstwie hutniczym*, *Logistyka* 2010, nr 4.

$$F_{i+1} = (1 - \frac{\alpha}{2}) \frac{Z_i}{P_i} \quad (5)$$

Model ARMA ( $p, q$ ) jest połączeniem procesu autoregresyjnego i procesu średniej ruchomej (6)<sup>8</sup>:

$$y_t = c + \Phi_1 y_{t-1} + \dots + \Phi_p y_{t-p} + \Theta_0 \varepsilon_t + \Theta_1 \varepsilon_{t-1} + \dots + \Theta_q \varepsilon_{t-q} \quad (6)$$

gdzie:

- $\Phi, \Theta$  — parametry modelu,
- $y_t$  — wartość prognozy w okresie  $t$ ,
- $\varepsilon_t$  — zdarzenie losowe z opóźnieniami,
- $c$  — stała.

Gdy stopień zintegrowania  $y_t$ , określane literą  $d$ , jest większy od zera, wówczas należy rozważyć model ARIMA ( $p, d, q$ ; *autoregressive-integrated moving average*).

Mianem predykcji ekonometrycznej określane jest wnioskowanie o nieznanych wartościach zmiennej objaśnianej, które dokonywane jest na podstawie modelu wyjaśniającego kształtowanie się wartości tej zmiennej<sup>9</sup>. W artykule wykorzystany zostanie model zbudowany w oparciu o doświadczenie regresji wielorakiej.

## Prognozowanie z wykorzystaniem SSN — koncepcja mikro, makro i hybrydowa

Przedstawione powyżej metody uznać można właściwie za metody klasyczne. Stosunkowo nowym trendem w dziedzinie prognozowania zapotrzebowania na części zamienne jest wykorzystanie jednej z metod sztucznej inteligencji — sztucznych sieci neuronowych SSN (Sztuczne Sieci Neuronowe; *Artificial Neural Networks*, ANN). Sieci neuronowe są wyrafinowaną techniką modelowania, zdolną do odwzorowywania bardzo złożonych funkcji. Sieci neuronowe zdobywają w ostatnich latach coraz większą popularność. Stanowią szeroko wykorzystywane narzędzie w wielu dziedzinach, m.in. w<sup>10</sup>:

- analizie problemów produkcyjnych,
- dobieraniu pracowników, materiałów wejściowych,
- diagnostyce układów elektronicznych, maszyn,
- planowaniu remontów maszyn,
- prognozowaniu sprzedaży,
- sterowaniu procesami przemysłowymi.

Sztuczne sieci neuronowe (SSN) stanowią metodę analityczną wzorującą swoje działanie na działaniu

mózgu. Pozwalają odtworzyć i zamodelować skomplikowane zależności zawarte w zbiorze danych. Zaletą tego podejścia jest to, że model zbudowany w oparciu o SSN jest modelem obiektywnym, tzn. opartym na danych, a nie na wiedzy analityka czy eksperta. Sieć neuronowa jest systemem, który dokonuje obliczeń na zasadzie symultanicznej pracy wielu połączonych ze sobą elementów (neuronów)<sup>11</sup>. Sztuczne neurony są uproszczonymi modelami komórek nerwowych występujących w przyrodzie. Charakteryzują się występowaniem wielu wejść i jednego wyjścia. Sygnały wejściowe  $x_i$  ( $i = 1, 2, \dots, n$ ) oraz sygnał wyjściowy  $y$  mogą przyjmować wartości, które odpowiadają pewnym informacjom. Neuron przetwarza informacje wejściowe na pewien wynik. Podstawowymi elementami neuronu są wartości wag  $w$ , funkcja wewnętrznego przetwarzania i funkcja aktywacji. Działanie sieci zależy od przyjętego modelu neuronu, liczby neuronów w warstwie ukrytej, wartości parametrów (wag) neuronu. Do podstawowych typów sieci neuronowych zalicza się: perceptron wielowarstwowy (*multilayer perceptron* MLP; uczenie z nauczycielem), sieć o radialnych funkcjach bazowych RBF (uczenie z nauczycielem), sieć Kohonena (uczenie bez nauczyciela). W części artykułu poświęconej badaniom empirycznym wykorzystywana będzie sieć najczęściej stosowana w modelowaniu, czyli sieć MLP (jednokierunkowa sieć wielowarstwowa). Sieć MLP zbudowana jest z warstwy wejściowej, warstwy/warstw ukrytej oraz warstwy wyjściowej.

Po analizie dostępnych w literaturze i w najnowszych opublikowanych badaniach metod prognozowania z wykorzystaniem SSN wyróżnić można trzy podejścia, które mogłyby stanowić efektywne narzędzie predykcji zapotrzebowania na części zamienne w przedsiębiorstwie z branży wydobywczej. Pierwsze z nich (można je określić jako podejście w skali mikro) zostało zaproponowane w pracy P. Kozika i J. Sępa<sup>12</sup>. Podejście to zastosowano w zarządzaniu remontami silników lotniczych (turbośmigłowy silnik lotniczy PZL 10W). SSN zbudowana na podstawie tej koncepcji opiera się na zbiorze zmiennych objaśniających, w skład którego wchodzi wewnętrzne i zewnętrzne charakterystyki eksploatacyjne silnika lotniczego (parametry otoczenia, parametry przy rozruchu, parametry pracy w zakresie mocy startowej). Przedstawiona w pracy koncepcja pozwoliła na poprawę trafności prognozy zapotrzebowania na części zapasowe i obniżenie kosztów eksploatacji. Podejście to wydaje się bardzo interesujące, m.in. przez fakt, że prognoza bu-

<sup>8</sup> M. Gruszczyński, T. Kuszewski, M. Podgórska, *Ekonometria...*, jw., s. 210–211.

<sup>9</sup> Tamże, s. 99.

<sup>10</sup> R. Knosala, *Zastosowania metod sztucznej inteligencji w inżynierii produkcji*, Wydawnictwa Naukowo-Techniczne, Warszawa 2002, s. 178.

<sup>11</sup> R. Tadeusiewicz, *Elementarne wprowadzenie do techniki sieci neuronowych z przykładowymi programami*, Akademicka Oficyna Wydawnicza PLJ, Warszawa 1998, s. 23.

<sup>12</sup> P. Kozik, J. Sęp, *Aircraft engine overhaul demand forecasting using ANN*, Management and Production Engineering Review, Vol. 3, No. 2, Czerwiec 2012, s. 21–26.

dowana jest na wielu niezależnych zmiennych, a nie tylko na poprzednich wartościach zapotrzebowania (zmiennej objaśnianej). Jednak wdrożenie tej koncepcji wymaga posiadania, gromadzenia i ciągłego monitorowania wielu danych. W przemyśle wydobywczym powodować to będzie dodatkowe obciążenie załogi obowiązkiem zbierania takich danych. Wykorzystanie tej koncepcji musiałoby pociągnąć za sobą przeszkolenie załogi w zakresie pozyskiwania odpowiednich danych, opracowanie sposobu ich przechowywania, segregacji oraz analizy. Dodatkowo należy wyjaśnić, dlaczego podejście to określono mianem mikro. Wydaje się ono zasadne do wprowadzenia np. w komorze maszyn ciężkich do prognozowania zapotrzebowania na wybrane części (komora nie posiada magazynu, są tam przechowywane głównie materiały i części podstawowe, szybko rotujące). Aby tę metodę prognozy stosować efektywnie, musiałyby być zbierane dane z każdego wozu, wiertnicy czy kotłowiarki. Jeśli natomiast metoda ta miałaby być używana w skali makro — tzn. przez np. cały magazyn — oznaczałoby to konieczność akwizycji danych ze wszystkich pracujących maszyn, które należy już liczyć w setkach. Implementacja takiego podejścia byłaby niezwykle kosztowna i prawdopodobnie niewspółmierna do oczekiwanych korzyści.

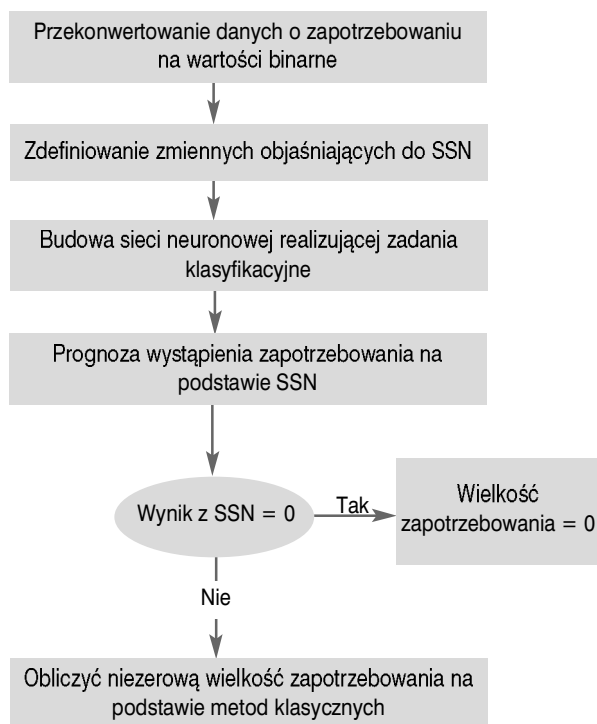
Drugim analizowanym podejściem (w skali makro) jest koncepcja prognozowania popytu na części zamienne oparta na zbiorze zmiennych, który zbudowany został na podstawie przebiegu wartości zapotrzebowania w poprzednich okresach. Podejście to opracowano na potrzeby pewnego przedsiębiorstwa z branży petrochemicznej<sup>13</sup>. Do obliczenia prognozy wykorzystano ponownie SSN. Dzięki tej metodzie odnotowano poprawę trafności prognozy zapotrzebowania na części zapasowe w porównaniu z innymi badanymi metodami, co pozwoliło na optymalizację poziomów magazynowych wybranych części. W części artykułu poświęconej badaniom empirycznym wykorzystana zostanie pewna modyfikacja tego podejścia.

W podejściu mikro i makro stosowane były sieci neuronowe zbudowane do realizacji zagadnień regresyjnych, których celem jest prognozowanie wartości określonej zmiennej. W takim przypadku na wyjściu sieci wymagana jest pojedyncza zmienna numeryczna. Należy zauważyć, że w problemach predykcyjnych można wyróżnić także drugą kategorię — klasyfikację.

Celem zagadnień klasyfikacyjnych jest przydzielenie rozpatrywanego przypadku do jednej ze zdefiniowanych wcześniej klas. Wówczas na wyjściu

<sup>13</sup> M.R. Amin-Naseri, B. Rostami Tabar, *Neural Network Approach to Lumpy Demand Forecasting for Spare Parts in Process Industries*, Proceedings of the International Conference on Computer and Communication Engineering 2008, May 13–15, Kuala Lumpur, Malaysia.

Rysunek 1  
Hybrydowe podejście do prognozowania zapotrzebowania na części zamienne



Źródło: opracowanie własne.

sieci wymagana jest pojedyncza zmienna nominalna. Najczęściej rozważane zagadnienia klasyfikacyjne mają charakter dwustanowy (często zerojedynkowy), chociaż problemy wielostanowe również są rozpatrywane. Trzecim podejściem jest metoda hybrydowa, która właśnie opiera się na SSN zbudowanej do realizacji zagadnień klasyfikacyjnych<sup>14</sup>. Algorytm postępowania w tej metodzie został schematycznie zaprezentowany na rysunku 1.

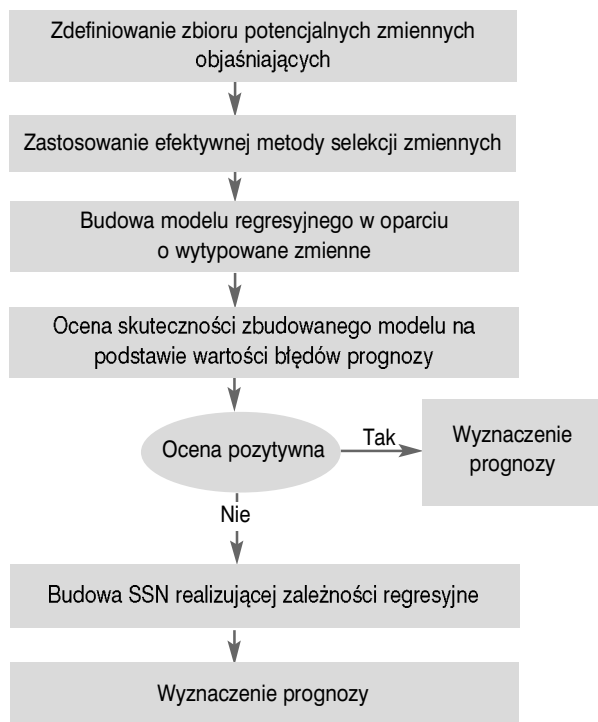
## Koncepcja prognozowania z wykorzystaniem kryteriów informacyjnych

Zaprezentowana w niniejszym artykule koncepcja jest pewną modyfikacją podejścia makro. Schemat postępowania zaproponowanej metody przedstawia rysunek 2. Krok pierwszy to zdefiniowanie zbioru potencjalnych zmiennych objaśniających —  $x_1, x_2, \dots, x_m$  (zmiennie wykorzystane w badaniach empirycznych zawiera tab. 2).

<sup>14</sup> A. Nasiri Pour, B. Rostami Tabar, A. Rahimzadeh, *A Hybrid Neural Network and Traditional Approach for Forecasting Lumpy Demand*, World Academy of Science, Engineering and Technology 2008 40.

Rysunek 2

Koncepcja prognozowania zapotrzebowania na części zamienne z wykorzystaniem kryteriów informacyjnych



Źródło: opracowanie własne.

W kolejnym kroku należy ustalić, które zmienne z wejściowego zbioru faktycznie wnoszą istotne informacje o kształtowaniu się zmiennej objaśnianej y (poziom zapotrzebowania na część zamienną Z). Do tego celu służą metody doboru zmiennych objaśniających. Istotne zagadnienie budowy modelu (sieci) stanowi właśnie problem doboru tych zmiennych. Wybór właściwego zbioru zmiennych objaśniających pozwala na zbudowanie modelu optymalnego, jest tym samym podstawowym, a wręcz krytycznym krokiem, umożliwiającym należyte prognozowanie danego zjawiska. Niewłaściwy dobór zmiennych objaśniających do modelu powoduje, że będzie on błędnie odzwierciedlał kształtowanie się analizowanych zależności lub też w ogóle nie będzie ich odzwierciedlał, w konsekwencji uniemożliwiając dokonanie wiarygodnych prognoz<sup>15</sup>. W pewnym okresie w budowie modeli istniała niesłuszna tendencja, żeby uwzględniać w badaniach możliwie największą liczbę zmiennych objaśniających. Liczba tych zmiennych przekraczała nawet czasem liczbę obserwacji w próbie. Powodowało to konieczność wykonywania wielu uciążliwych i obszernych obliczeń, natomiast uzyska-

<sup>15</sup> M. Rosienkiewicz, *Porównanie metod Akaike i Hellwiga w zakresie efektywności konstrukcji modelu regresyjnego*, Wiadomości Statystyczne 2012, nr 10.

ne wyniki często były pozbawione większego znaczenia praktycznego. Wystąpiła potrzeba, aby ograniczyć liczbę zmiennych objaśniających już we wczesnym etapie badań. Niezwykle istotnym problemem jest zatem wykorzystywanie przy konstrukcji modelu odpowiedniej metody doboru zmiennych objaśniających. W literaturze światowej można znaleźć bardzo wiele sposobów wiodących do tego celu, jednak najpopularniejsze z nich to kryterium informacyjne Akaike (*Akaike's information criterion, AIC*) oraz kryterium informacyjne Schwarza (*Schwarz information criterion, BIC*). W literaturze polskiej natomiast najczęściej opisywaną metodą doboru zmiennych objaśniających jest metoda wskaźników pojemności informacji Z. Hellwiga. Dość znaną jest też metoda entropii krzyżowej (*Cross Entropy, CE*).

H. Akaike zaproponował kryterium AIC wyboru modelu, które może być interpretowane jako miara odległości pomiędzy modelem dopasowanym do zebranych, niekompletnych danych statystycznych, a modelem efektywnym, który wygenerował te dane<sup>16</sup>. Kryterium AIC opiera się na estymacji informacji Kullbacka-Leiblera za pomocą metody największej wiarygodności. H. Akaike wyprowadził kryterium informacyjne AIC (7) postaci:

$$AIC(\hat{\theta}) = -2\ln\hat{L} + 2p, \quad (7)$$

gdzie:

$p$  — liczba parametrów modelu (liczba zmiennych objaśniających wraz z wyrazem wolnym),

$\hat{L} = L(\hat{\theta}) = \max\{L(\theta_i, D)\}$  — maksimum funkcji wiarygodności dla estymowanego modelu.

Kryterium H. Akaike jest obecnie bardzo popularne i często stosowane w różnych dziedzinach nauki. Stanowi właściwie uniwersalne kryterium wyboru optymalnego modelu. Należy jednak być ostrożnym przy stosowaniu tej metody i nie przyjmować otrzymanych wyników bezkrytycznie. W artykule T.W. Arnolda można znaleźć ważne spostrzeżenie dotyczące kryterium informacyjnego Akaike<sup>17</sup>.

G. Schwarz zaproponował nieco inne podejście do omówionego problemu. Otóż przedstawił następujące kryterium wyboru modelu BIC (8) postaci<sup>18</sup>:

$$M_j(X_1, \dots, X_n) \frac{1}{2} k_j \log n, \quad (8)$$

<sup>16</sup> J.E. Cavanaugh, R.H. Shumway, *An Akaike Information Criterion for Model Selection in the Presence of Incomplete Data*, Journal of Statistical Planning and Inference, Volume 67, Issue 1, 16 March 1998.

<sup>17</sup> T.W. Arnold, *Uninformative Parameters and Model Selection Using Akaike's Information Criterion*, Journal of Wildlife Management 74 (6): 1175–1178; 2010; DOI: 10.2193/2009-367, s. 1175–1178.

<sup>18</sup> G. Schwarz, *Estimating the dimension of a model*, The Annals of Statistics 1978, Vol. 6, No. 2, s. 461–464.

gdzie:

$M_j(X_1, \dots, X_n)$  — maksimum funkcji wiarygodności,

$k_j$  — wymiar modelu (liczba parametrów modelu),

$n$  — wielkość próby.

Kryterium BIC (8) różni się od kryterium H. Akaike AIC (7) przemnożeniem rozmiaru modelu (mierzonego przez liczbę parametrów modelu  $k_j$ ) przez  $\frac{1}{2} \log n$ <sup>19</sup>. Pod względem jakościowym zarówno procedura G. Schwarz'a jak i H. Akaike umożliwia „matematyczne sformułowanie zasady skąpstwa (*the principal of parsimony*) w budowaniu modeli”. Jednak pod względem ilościowym kryterium G. Schwarz'a skłania się bardziej niż kryterium H. Akaike ku modelom o mniejszych rozmiarach (*lower-dimensional models*). Z perspektywy bayesowskiej kryterium BIC jest tak opracowane, aby wskazywać najbardziej prawdopodobny model dla określonego zbioru danych.

Statystyczna interpretacja pojęcia entropii została rozwinięta głównie dzięki pracom St. Boltzmanna, J.C. Maxwella i M. Smoluchowskiego. W ramach teorii informacji niepewność o nieznannej zmiennej jest określana ilościowo przez wielkość zwaną entropią. Dodatkowa wiedza o innych badanych zmiennych przyczynia się do redukcji entropii i dzięki temu informacja o nieznannej zmiennej wzrasta<sup>20</sup>. Entropia krzyżowa (*cross entropy*) jest miarą odstępstwa rozkładu teoretycznego  $P$  od empirycznego  $P_e$ . Entropię krzyżową definiuje wzór (9):

$$H(P_e \| P) = - \sum_{x \in X} P_e(x) \log P(x) = H(P_e) + D(P_e \| P) \geq 0, \quad (9)$$

gdzie:

$P_e$  — rozkład teoretyczny,

$P$  — rozkład empiryczny.

Powyzszą miarę stosuje się do identyfikacji rozkładu teoretycznego. Dla ustalonych wartości rozkładu empirycznego  $P_e$  minimalizowana jest wartość (10):

$$H(P_e \| P) \text{ dla } P_e = P. \quad (10)$$

W pakiecie  $R$  (*R language*), w którym wykonywane były obliczenia, entropia krzyżowa jest wyliczana w oparciu o algorytm  $k$  najbliższych sąsiadów kNN (*k nearest neighbours*) — kNN *Cross Entropy Estimators*<sup>21</sup>.

W metodzie wskaźników pojemności informacji

Z. Hellwiga procedura wyboru optymalnego zbioru zmiennych objaśniających polega na tym, że dla każdej zmiennej z kombinacji wyznaczana jest *indywidualna pojemność nośników informacji*  $h_{kj}$  (11)<sup>22</sup>:

$$h_{kj} = \frac{r_j^2}{\sum |r_{ij}|}, \quad (11)$$

gdzie:

$k$  — numer kombinacji ( $k = 1, 2, \dots, 2^m - 1$ ),

$j$  — numer zmiennej w danej kombinacji,

$r_j$  — współczynnik korelacji potencjalnej zmiennej objaśniającej o numerze  $j$  ze zmienną objaśniającą,

$r_{ij}$  — współczynnik korelacji między  $i$ -tą i  $j$ -tą potencjalną zmienną objaśniającą.

Wskaźnik  $h_{kj}$  mierzy wielkość informacji, jaką zmienna  $X_j$  wnosi o zmiennej objaśnianej  $Y$  w  $k$ -tej kombinacji. Po wyznaczeniu wartości  $h_{kj}$  dla wszystkich zmiennych oblicza się dla każdej kombinacji *pojemność integralną kombinacji nośników informacji*  $H_k$  (12). Wyznacza się ją dla każdej kombinacji według wzoru:

$$H_k = \sum h_{kj}. \quad (12)$$

Jest ona sumą indywidualnych pojemności nośników informacji, które wchodzi w skład danej kombinacji. Wybór odpowiedniej kombinacji zmiennych objaśniających następuje na podstawie pojemności informacji, mierzonej wskaźnikiem  $H_k$ . Według tego kryterium należy wybrać kombinację zmiennych, która wnosi najwięcej informacji, czyli taką, dla której  $H_k$  osiąga najwyższą wartość.

We wcześniejszych badaniach analizowano, która z przedstawionych czterech metod jest bardziej efektywnym narzędziem selekcji zmiennych. Aby na to pytanie odpowiedzieć, opracowany został specjalny program w środowisku  $R$  (*R language*). Celem prowadzonych badań było porównanie efektywności przedstawionych metod selekcji zmiennych, zweryfikowanie ich, odpowiedź na pytanie czy skuteczność poszczególnych metod różni się w zależności od rodzaju rozkładu prawdopodobieństwa zmiennych, a także ocena efektywności poszczególnych metod w zależności od rozmiaru modelu, wielkości próby i wielkości zbioru potencjalnych zmiennych objaśniających. Zagadnienie analizy efektywności wybranych metod selekcji zmiennych nie jest przedmiotem tego artykułu, zostaną więc jedynie skrótowo przedstawione rezultaty badań.

Po przeprowadzeniu dogłębnej analizy wyników pochodzących z badań symulacyjnych można stwier-

<sup>19</sup> H. Acquah de-Graft, *Comparison of Akaike information criterion (AIC) and Bayesian information criterion (BIC) in selection of an asymmetric price relationship*, Journal of Development and Agricultural Economics Vol. 2 (1) pp. 001–006, January, 2010.

<sup>20</sup> D. Ramos, J. Gonzalez-Rodriguez, *Cross-entropy Analysis of the Information in Forensic Speaker Recognition*, Proceedings of IEEE Odyssey, January 2008.

<sup>21</sup> S. Boltz, E. Debreuve, M. Barlaud, *kNN-based high-dimensional Kullback-Leibler distance for tracking*, Eighth International Workshop on Image Analysis for Multimedia Interactive Services (WIAMIS'07), IEEE 2007.

<sup>22</sup> J. Dziechciarz, *Ekonomometria. Metody, przykłady, zadania*, Wydawnictwo Akademii Ekonomicznej im. Oskara Langego we Wrocławiu, Wrocław 2002, s. 51–52.

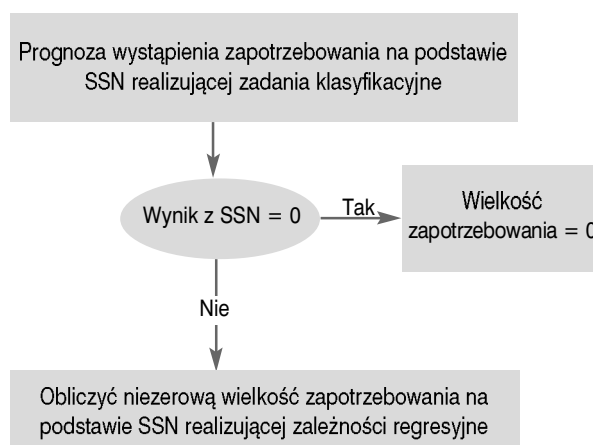
dzić, że najefektywniejszym narzędziem selekcji modelu jest kryterium informacyjne G. Schwarza BIC. Kryterium to jest najskuteczniejsze w wypadku bardzo licznych prób ( $n = 500$  i  $n = 1000$ ) — wtedy prawdopodobieństwo wskazania przez to kryterium optymalnego zbioru zmiennych mających wejść do modelu przekracza 90%. Z kolei dla prób mniej licznych ( $n = 50$ ,  $n = 100$ ) skuteczność kryteriów H. Akaike i G. Schwarza jest porównywalna. W przypadku niektórych modeli bardziej skuteczne jest kryterium AIC, a w innych BIC. Nie można jednoznacznie stwierdzić, która metoda jest lepszym narzędziem. Należy jednak zaznaczyć, że kryteria informacyjne stanowią bezsprzecznie zdecydowanie skuteczniejsze narzędzie wyboru odpowiedniej postaci modelu w porównaniu do pozostałych badanych metod. Dokonane analizy wykazały również, że metodę wskaźników pojemności informacji Z. Hellwiga i metodę entropii krzyżowej charakteryzuje bardzo niska skuteczność w selekcji prawidłowych zmiennych, które powinny wejść do modelu. Należy zatem zdecydowanie odradzić stosowanie tych metod jako kryteriów wyboru postaci modelu (zmiennych objaśniających).

Opierając się na otrzymanych wynikach, należy zatem w kroku drugim prezentowanego podejścia korzystać z kryteriów informacyjnych AIC oraz BIC. Krok kolejny to budowa modelu regresyjnego w oparciu o wyselekcjonowane zmienne, a następnie należy ocenić skuteczności zbudowanego modelu na podstawie prognozowanych błędów. W tym miejscu należy się pewne wyjaśnienie — dlaczego stosowany jest najpierw model regresyjny, a dopiero w kolejnych krokach budowa SSN? Otóż jeżeli zbudowany model regresyjny będzie efektywnym narzędziem prognozy, wówczas dużo łatwiej z niego korzystać potencjalnemu użytkownikowi. Może on zostać zaimplementowany nawet do arkusza kalkulacyjnego (np. Excel). Dlatego też nie ma sensu sięgać po zbyt zaawansowane narzędzie prognozy, kiedy nie ma takiej potrzeby. Parametry modelu są też dużo łatwiejsze w interpretacji. Natomiast kolejny krok jest istotny w momencie, w którym może się okazać, że model regresyjny nie jest wystarczającym narzędziem prognozowania. A zatem następuje ocena czy model regresyjny jest efektywnym narzędziem predykcji — jeśli tak, wówczas należy wyliczyć prognozę, jeśli nie, wtedy należy zbudować sieć neuronową w oparciu o zebrane wcześniej dane. W ostatnim kroku wyliczana jest prognoza.

W przeprowadzonych badaniach przeanalizowano także koncepcję hybrydową. Zmodyfikowano jednak nieco to podejście: po otrzymaniu z sieci wyniku różnego od zera (1) kolejnym krokiem było wyznaczenie prognozy z sieci neuronowej — ale regresyjnej (nie klasyfikacyjnej), w przeciwieństwie do sposobu prognozowania proponowanego w podejściu hybrydowym — metodą klasyczną. Schemat postępowania przedstawia rysunek 3.

Rysunek 3

Modyfikacja podejścia hybrydowego



Źródło: opracowanie własne.

Okazało się, że tak prowadzone obliczenia dają wyniki praktycznie tożsame z podejściem, w którym prognoza pochodzi z sieci neuronowej, w której zmienną zależną jest zapotrzebowanie, a nie zapotrzebowanie przekonwertowane na wartości binarne, czyli z sieci realizującej zależność regresyjną. Dlatego też w niniejszym artykule nie zamieszczono wyników pochodzących z obliczeń wykorzystujących podejście hybrydowe.

## Analiza efektywności wykorzystania kryteriów informacyjnych w predykcji zapotrzebowania

W artykule zaprezentowano trzy podejścia — mikro (zastosowane w zarządzaniu remontami silników lotniczych), „makro” i hybrydowe (podejście zastosowane w przedsiębiorstwie z branży petrochemicznej). W empirycznej części pracy wykorzystano podejście omówione powyżej (zaprezentowane schematycznie na rys. 2), a następnie porównano otrzymane wyniki z prognozami pochodzącymi z klasycznych metod (SES, SBA, MA, ARIMA). Zbadano także, czy sieci neuronowe zbudowane w oparciu o zbiory zmiennych wyselekcjonowane przez kryteria informacyjne są skuteczniejszym narzędziem prognozowania niż SSN zbudowane na zbiorach zawierających wszystkie potencjalne zmienne objaśniające.

Dane, które posłużyły do przeprowadzenia obliczeń empirycznych, pochodzą z pewnego przedsiębiorstwa z przemysłu wydobywczego. Zostały pozyskane z systemu typu ERP. W tabeli 2 przedstawiono zbiór potencjalnych zmiennych objaśniających, który został wykorzystany w analizie. Zmienne  $x_1$ – $x_9$  zostały wyliczone na podstawie przebiegu wartości zapotrzebowania  $y$  w czasie.

Tabela 2

Zbiór potencjalnych zmiennych objaśniających

| Oznaczenie | Zmienne   |
|------------|---|
| $x_1$      | Liczba dni pomiędzy dwoma ostatnimi zamówieniami w okresie bezpośrednio poprzedzającym okres prognozy                   |
| $x_2$      | Liczba dni pomiędzy okresem prognozy i pierwszym niezerowym zapotrzebowaniem bezpośrednio poprzedzającym okres prognozy |
| $x_3$      | Liczba dni pomiędzy okresem prognozy i pierwszym zerowym zapotrzebowaniem bezpośrednio poprzedzającym okres prognozy    |
| $x_4$      | Średnie zapotrzebowanie (w szt.) z 6 dni bezpośrednio poprzedzających okres prognozy                                    |
| $x_5$      | Maksymalne zapotrzebowanie (w szt.) z 6 dni bezpośrednio poprzedzających okres prognozy                                 |
| $x_6$      | Sumaryczne zapotrzebowanie (w szt.) w ostatnim tygodniu poprzedzającym okres prognozy                                   |
| $x_7$      | Liczba dni w tygodniu poprzedzającym okres prognozy, w których wystąpiło zapotrzebowanie                                |
| $x_8$      | Liczba dni w tygodniu poprzedzającym okres prognozy, w których nie wystąpiło zapotrzebowanie                            |
| $x_9$      | Średnie zapotrzebowanie z 2 tygodni bezpośrednio poprzedzających okres prognozy   |
| $x_{10}$   | Trend czasowy   |
| $y$        | Wartość zapotrzebowania (w szt.)  |

Źródło: opracowanie własne.

Analizie poddano dane dotyczące trzech typów części zamiennych, które dla potrzeb artykułu oznaczone zostaną jako A, B i C. Wybór tych części nastąpił po dogłębnej, dwuetapowej analizie awaryjności. W pierwszej kolejności zbadano poziom awaryjności poszczególnych grup maszyn. Przeanalizowano między innymi wartości wskaźników MTTF, MTTR i MTBF. Następnie po wyborze typu maszyny przeanalizowano pod kątem awaryjności poszczególne zespoły maszyny. Wybrano reprezentantów dla trzech różnych zespołów. Zarówno każdy zespół, jak i wszystkie części charakteryzuje bardzo wysoki współczynnik awaryjności. Dla części A wielkość próby wynosiła  $n = 1741$  dni, dla części B  $n = 1035$  dni, a dla części C  $n = 728$  dni. Kryterium oceny efektywności prognoz wyznaczonych według poszczególnych metod stanowiły:

- średni błąd predykcji (*mean error* ME),
- średni błąd absolutny (*mean absolute error* MAE),
- pierwiastek błędów średniokwadratowego (*root mean square error* RMSE),
- pierwiastek kwadratowy ze współczynnika Theila (I) — względny błąd prognozy *ex post*,
- współczynnik determinacji  $R^2$ .

Zmienne wyselekcjonowane przez kryterium AIC to dla części A:  $x_2, x_3, x_4, x_5, x_7$ , dla części B:  $x_3, x_4, x_5, x_7$ , dla części C:  $x_3, x_5, x_6, x_7$ . Zmienne wyselekcjonowane przez kryterium BIC to dla części A:  $x_2, x_3, x_4, x_7$ , dla części B:  $x_3, x_5, x_7$ , dla części C:  $x_3, x_5, x_6, x_7$  (ob-

liczenia dotyczące selekcji zmiennych przeprowadzane były w programie R).

W tabelach 3, 4, 5 zamieszczono wyniki przeprowadzonych obliczeń. Analizowane metody prognozowania oznaczono następująco:

- SES (0,1) — metoda wygładzania wykładniczego,  $\alpha = 0,1$ .
- SBA (0,1) — metoda Syntetosa-Boylana,  $\alpha = 0,1$  (wzór (5)).
- MA (7) — metoda średniej ruchomej MA,  $k = 7$  (wzór (1)).
- ARIMA (1,0,1) — model ARIMA.
- Model regresyjny — predykcja ekonometryczna.
- SSN (10 zm.) — sztuczna sieć neuronowa zbudowana na pełnym zbiorze zmiennych objaśniających (10 zmiennych).
- SSN (AIC) — sztuczna sieć neuronowa zbudowana w oparciu o zmienne wyselekcjonowane przez kryterium Akaike.
- SSN (BIC) — sztuczna sieć neuronowa zbudowana w oparciu o zmienne wyselekcjonowane przez kryterium Schwarza.
- SSN (10 zm., zb. walid.) — sztuczna sieć neuronowa zbudowana na pełnym zbiorze zmiennych objaśniających (10 zmiennych), zbiór walidacyjny.
- SSN (AIC, zb. walid.) — sztuczna sieć neuronowa zbudowana w oparciu o zmienne wyselekcjonowane przez kryterium Akaike, zbiór walidacyjny.
- SSN (BIC, zb. walid.) — sztuczna sieć neuronowa zbudowana w oparciu o zmienne wyselekcjonowane przez kryterium Schwarza, zbiór walidacyjny.

Warto podkreślić, że w przypadku sztucznych sieci neuronowych SSN przedstawiono wyniki dwojako — dla całej sieci, tzn. dla wszystkich przypadków (zbioru uczącego, testowego i walidacyjnego), aby możliwe było porównanie wyników z pozostałymi metodami dla takiej samej wielkości próby, a osobno przedstawiono wyniki pochodzące ze zbioru walidacyjnego. Proces walidacji polega na tym, że pewna liczba przypadków uczących jest zaliczana do oddzielnej grupy. Dane należące do tej wydzielonej grupy nie są bezpośrednio stosowane w trakcie uczenia sieci. Natomiast są one wykorzystywane do przeprowadzenia niezależnej kontroli postępów algorytmu uczenia. Właściwie ocena jakości całej sieci powinna następować na podstawie oceny zbioru walidacyjnego. Obliczenia dotyczące SSN i modeli ARIMA przeprowadzane były w programie „Statistica”

Przedstawione wyniki wskazują na zdecydowaną przewagę prognoz pochodzących z SSN, bez względu na kryterium oceny, dla trzech badanych części. Klasykne metody predykcji zupełnie nie spełniają swojej roli. Analizując otrzymane dla nich wartości względnych błędów prognozy *ex post* [pierwiastek kwadratowy ze współczynnika Theila (I)], można zauważyć, że prognozy zapotrzebowania obciążone są bardzo dużymi błędami oscylującymi wokół 90–100%. Z kolei wartości te są znacznie niższe w przypadku prognoz



**Tabela 3**  
Wyniki otrzymane dla części A

| Metoda prognozowania     | ME     | MAE   | RMSE  | I     | R <sup>2</sup> |
|--------------------------|--------|-------|-------|-------|----------------|
| SES (0,1)                | 0,005  | 1,641 | 3,610 | 1,002 | 0,070          |
| SBA (0,1)                | 0,737  | 0,989 | 3,580 | 1,000 | 0,060          |
| MA (7)                   | -0,007 | 1,647 | 3,750 | 1,045 | 0,160          |
| ARIMA (1,0,1)            | 0,816  | 0,918 | 3,580 | 0,998 | 0,060          |
| Model regresyjny         | 0,000  | 0,609 | 1,820 | 0,505 | 0,730          |
| SSN (10 zm.)             | -0,018 | 0,140 | 1,240 | 0,344 | 0,870          |
| SSN (AIC)                | -0,004 | 0,120 | 1,230 | 0,342 | 0,880          |
| SSN (BIC)                | -0,004 | 0,120 | 1,230 | 0,342 | 0,880          |
| SSN (10 zm., zb. walid.) | -0,068 | 0,133 | 0,490 | 0,125 | 0,980          |
| SSN (AIC, zb. walid.)    | -0,056 | 0,089 | 0,450 | 0,115 | 0,990          |
| SSN (BIC, zb. walid.)    | -0,056 | 0,089 | 0,450 | 0,115 | 0,990          |

Źródło: opracowanie własne.

**Tabela 4**  
Wyniki otrzymane dla części B

| Metoda prognozowania     | ME     | MAE   | RMSE  | I     | R <sup>2</sup> |
|--------------------------|--------|-------|-------|-------|----------------|
| SES (0,1)                | 0,009  | 3,949 | 7,340 | 0,965 | 0,050          |
| SBA (0,1)                | 1,785  | 3,003 | 7,410 | 0,973 | 0,070          |
| MA (7)                   | 0,000  | 4,076 | 7,640 | 1,005 | 0,140          |
| ARIMA (0,0,0) (1,0,1)    | 0,517  | 3,358 | 7,110 | 0,935 | 0,010          |
| Model regresyjny         | 0,000  | 2,606 | 5,510 | 0,725 | 0,410          |
| SSN (10 zm.)             | -0,187 | 1,152 | 3,010 | 0,396 | 0,820          |
| SSN (AIC)                | 0,012  | 0,933 | 2,860 | 0,376 | 0,840          |
| SSN (BIC)                | -0,003 | 0,843 | 2,660 | 0,349 | 0,860          |
| SSN (10 zm., zb. walid.) | -0,410 | 0,877 | 2,200 | 0,527 | 0,670          |
| SSN (AIC, zb. walid.)    | -0,133 | 0,586 | 1,660 | 0,396 | 0,810          |
| SSN (BIC, zb. walid.)    | -0,048 | 0,472 | 1,380 | 0,331 | 0,870          |

Źródło: opracowanie własne.

**Tabela 5**  
Wyniki otrzymane dla części C


| Metoda prognozowania     | ME     | MAE   | RMSE  | I     | R <sup>2</sup> |
|--------------------------|--------|-------|-------|-------|----------------|
| SES (0,1)                | 0,317  | 1,859 | 2,460 | 0,721 | 0,030          |
| SBA (0,1)                | 0,662  | 2,149 | 3,770 | 1,101 | 0,280          |
| MA (7)                   | 0,098  | 1,924 | 2,530 | 0,741 | 0,020          |
| ARIMA (1,0,1)            | -0,104 | 1,949 | 2,440 | 0,716 | 0,050          |
| Model regresyjny         | 0,000  | 0,271 | 0,650 | 0,620 | 0,580          |
| SSN (10 zm.)             | 0,001  | 0,006 | 0,070 | 0,070 | 1,000          |
| SSN (AIC)                | 0,004  | 0,006 | 0,070 | 0,060 | 1,000          |
| SSN (BIC)                | 0,002  | 0,003 | 0,030 | 0,030 | 1,000          |
| SSN (10 zm., zb. walid.) | 0,000  | 0,013 | 0,110 | 0,250 | 0,930          |
| SSN (AIC, zb. walid.)    | 0,004  | 0,046 | 0,160 | 0,150 | 0,980          |
| SSN (BIC, zb. walid.)    | 0,000  | 0,008 | 0,080 | 0,190 | 0,960          |

Źródło: opracowanie własne.

wyliczonych z wykorzystaniem SSN. Można, przykładowo, zauważyć dla części A, że względny błąd prognozy *ex post* (I) dla SSN (10 zm., zb. walid.) zbudowanej na 10 zmiennych, dla zbioru walidacyjnego nie przekroczył 12,5%, dla SSN (AIC, zb. walid.) zbudowanej na zmiennych wytypowanych przez kryterium AIC i dla SSN (BIC, zb. walid.) zbudowanej na zmiennych wytypowanych przez kryterium BIC, dla zbioru walidacyjnego, nie przekroczył 11,5%. Z kolei w przypadku części B współczynnik determinacji  $R^2$  wyniósł dla SSN (10 zm., zb. walid.) 0,67, co świadczy o nie najlepszym dopasowaniu modelu do danych empirycznych, w ponad 67% wyjaśnia on zmienność zapotrzebowania. Z kolei dla SSN (AIC, zb. walid.)  $R^2$  wyniósł 0,81, co świadczy o dość dobrym dopasowaniu modelu do danych empirycznych, a zatem w 81% wyjaśnia on zmienność zapotrzebowania.  $R^2$  wynoszący 0,87 dla SSN (BIC, zb. walid.) oznacza bardzo dobre dopasowanie modelu do danych empirycznych, a zatem w 87% wyjaśnia on zmienność zapotrzebowania na część B.

Rysunek 4

Porównanie efektywności poszczególnych metod prognozowania na podstawie pierwiastka kwadratowego ze współczynnika Theila (I)



Źródło: opracowanie własne.

Na rysunkach 4 i 5 wyszczególniono wyniki dotyczące zaproponowanej w pracy koncepcji prognozowania. Przedstawione wyniki świadczą o słuszności zastosowania kryteriów informacyjnych w procesie budowania prognozy. Przykładowo, dla części B względny błąd prognozy *ex post* (I) nie przekroczył dla modelu regresyjnego (predykcja ekonometryczna) 72,5%, dla SSN zbudowanej na 10 zmiennych na pełnym zbiorze danych 40%, dla SSN zbudowanej na zmiennych wyselekcjonowanych przez kryterium AIC na pełnym zbiorze danych 38%, dla SSN zbudowanej na zmiennych wyselekcjonowanych przez kryterium BIC na pełnym zbiorze danych 35%.

Z kolei w przypadku wyników otrzymanych tylko dla danych ze zbioru walidacyjnego względny błąd


prognozy *ex post* (I) nie przekroczył 53% dla SSN zbudowanej na 10 zmiennych, 40% dla SSN zbudowanej na zmiennych wskazanych przez kryterium AIC i 33% dla SSN zbudowanej na zmiennych wytypowanych przez kryterium BIC. Po analizie wyników zamieszczonych na rysunkach 4 i 5 można stwierdzić, że najniższe błędy prognozy i najwyższy współczynnik determinacji charakteryzują prognozy wyznaczone w oparciu o zmienne wyselekcjonowane metodą Schwarza (BIC). Także prognozy obliczone na podstawie zmiennych wytypowanych metodą Akaike (AIC) okazały się trafniejsze od prognoz zbudowanych na pełnym zbiorze potencjalnych zmiennych objaśniających. Prognozowanie na podstawie modelu regresyjnego nie okazało się zbyt skuteczne dla analizowanych zmiennych. Jedyne w przypadku części A współczynnik determinacji osiągnął poziom 73%, co oznacza, że w 73% model wyjaśnia zmienność zapotrzebowania.

## Podsumowanie

Po przeanalizowaniu wyników otrzymanych w ramach obliczeń przeprowadzonych na danych empirycznych można zauważyć, że zbadane w pracy metody klasyczne — wygładzania wykładniczego SES, metody Syntetosa-Boylana SBA, średniej ruchomej MA, ARIMA — charakteryzuje bardzo niska skuteczność w predykcji zapotrzebowania na części zamienne. W związku z tym należy zrezygnować z wykorzystywania ich jako narzędzi prognozowania. Wyznaczone prognozy, poddane ocenie poprzez wyliczenie stosowanych miar błędów predykcji (ME, MAE, RMSE, I,  $R^2$ ), świadczą o tym, że zapropono-

Rysunek 5

Porównanie efektywności poszczególnych metod prognozowania na podstawie współczynnika determinacji



Źródło: opracowanie własne.

wana w pracy metoda prognozowania może stać się efektywnym narzędziem budowania prognoz zapotrzebowania na części zamienne w przemyśle wydobywczym. Wyniki badań otrzymanych dla modeli regresyjnych (predykcja ekonometryczna) wykazały, że błędy prognoz otrzymywane tą metodą są znacznie mniejsze od błędów metod klasycznych, jednak przewyższają błędy prognoz otrzymanych metodą SSN. Należy więc podkreślić, że zasadność stosowania modeli regresyjnych jako metod prognozowania zależy od dopuszczalnego błędu, jaki ustanowi użytkownik prognozy. Jeśli uzna, przykładowo, że poziom błędów prognozy nieprzekraczający 50% i wartość współczynnika determinacji powyżej 70% są zadowalające, wówczas postępując zgodnie z zaprezentowaną w pracy metodą należy obrać ścieżkę, na której model uzyskuje ocenę pozytywną, nie ma więc potrzeby konstruowania SSN i w oparciu o model regresyjny można wyliczyć prognozę. Jeśli natomiast użytkownik uzna, że taki poziom błędów jest zbyt wysoki, wtedy powinien, zgodnie z opracowaną metodą, obrać ścieżkę, na której model uzyskuje ocenę negatywną, a w kolejnym kroku budowana jest SSN.

Podsumowując otrzymane rezultaty, należy stwierdzić, że sztuczne sieci neuronowe stanowią bardzo skuteczną alternatywę dla metod klasycznych. Można uznać je za efektywne narzędzie prognozowania zapotrzebowania na części zamienne w przemyśle wydobywczym. Otrzymane rezultaty świadczą ponadto o tym, że zastosowanie kryteriów informacyjnych (Schwarza i Akaike) na etapie budowy modelu (sieci) pozwala na zwiększenie trafności prognozy zapotrzebowania na części zamienne. Można więc przyjąć, że zaproponowana w pracy koncepcja powinna stać się przydatnym i efektywnym narzędziem budowania prognoz zapotrzebowania na części zamienne. Jego zastosowanie może wspomóc proces zarządzania częściami zamiennymi między innymi poprzez eliminację kosztów i strat wywołanych utrzymywaniem nadmiernych zapasów lub też wynikających z braku części zamiennych.

Projekt systemowy *GRANT PLUS* Program Operacyjny Kapitał Ludzki, Priorytet VIII Regionalne Kadry Gospodarki, Działanie 8.2 Transfer Wiedzy, Poddziałania 8.2.2 Regionalne Strategie Innowacji.

## Summary

### Efficiency analysis of information criteria application in spare parts demand forecasting

The paper presents a new approach to the spare parts forecasting issue — a method which combines regression modeling, information criteria and artificial neural networks ANN. The research presented in this article compares efficiency of classical methods with the artificial intelligence tool in the scope of spare parts forecasting. Artificial Neural Networks have been advocated as an alternative to traditional statistical forecasting methods. Classical methods, such as exponential smoothing or mean average, have been used for several decades in forecasting demand. However, many of these techniques may perform poorly when demand for an item is lumpy or intermittent. In the paper three concepts of using ANN in spare parts forecasting — micro, macro and hybrid — were described. The article presents also the variable selection issue, which is of a great importance in any model building.