

Kolegium Analiz Ekonomicznych

Autoreferat

**Model prognozowania popytu w przemyśle
hutniczym**

Magdalena Barska

Warszawa 2021

Temat pracy i uzasadnienie wyboru

Opracowanie „Model prognozowania popytu w przemyśle hutniczym” poświęcone jest analizie popytu i sprzedaży na wyroby przedsiębiorstwa reprezentującego branżę hutnictwa żelaza i stali. Mowa w tym przypadku o popycie zrealizowanym, którego miarą jest konsumpcja. Prognozowaniu popytu dla rynków przemysłowych poświęca się znacznie mniej uwagi niż dobrom konsumpcyjnym, a sam popyt kształtowany jest przez inne czynniki. Należą do nich: koniunktura, cykl życia produktów, działania konkurencji, uwarunkowania polityczne i środowiskowe. Ciekawym wydaje się zatem zbadanie tych zależności.

Analiza przyszłych wielkości popytu i sprzedaży jest istotnym aspektem działalności przedsiębiorstwa. Szacowanie wielkości zapotrzebowania na dobra i usługi jest niezbędne do określenia zasobów, materiałów wykorzystywanych w procesie produkcji oraz do planowania zatrudnienia. Zarówno nadwyżka jak i niedobór produkcji są dla przedsiębiorstwa niekorzystne. W przypadku nadwyżki ponosi ono koszty składowania i utylizacji produktu. Niedobór wiąże się z kosztem utraconych możliwości lub utratą klientów.

Wiele przedsiębiorstw przekonanych jest o wyższości metod jakościowych i przygotowanie prognozy powierza wewnętrznym ekspertom. Obawiają się dodatkowych kosztów i złożoności metod ilościowych, co znacznie ogranicza ich stosowanie. Jednocześnie środowisko działania współczesnych firm charakteryzuje się niespotykaną dotąd zmiennością i zastosowanie prognozowania ekonometrycznego wydaje się być konieczne w zbadaniu złożonych zależności między zjawiskami. Dobry model prognostyczny może służyć walidacji wyniku prognozy jakościowej albo stać się etapem procesu prognostycznego.

Kolejnym interesującym zagadnieniem jest dobór samego modelu i identyfikacja zmiennych wpływu. Biorąc pod uwagę specyfikę hutnictwa, długi okres produkcji, zależność od polityki gospodarczej i środowiskowej, model powinien pozwalać na wydłużenie horyzontu prognozy i odzwierciedlać wpływ niemierzalnych czynników. Branża hutnicza produkuje dla innych przemysłów, rzadziej dla indywidualnych klientów. Wahania popytu są uzależnione od ogólnej kondycji gospodarki. W literaturze wiele jest przykładów prognozowania zjawisk ekonomicznych dla przemysłów o zbliżonej charakterystyce. Interesujące byłoby sprawdzenie, czy mają zastosowanie w hutnictwie.

Wielu autorów odnosiło się do ograniczeń prognozowania z użyciem metod klasycznych. Głównym zarzutem wobec nich jest bazowanie wyłącznie na danych historycznych oraz nieuwzględnienie losowego charakteru zjawiska. Z tego względu

w opracowaniu podjęto próbę budowy wariantów modelu uwzględniającego zmienne ukryte, jak alternatywy dla podejścia klasycznego.

Ciekawym aspektem analizy jest także sytuacja hutnictwa w Polsce. W obliczu wyzwań i możliwości, przed którymi stoi przemysł hutniczy, odpowiednia strategia może przyczynić się do jego dynamicznego rozwoju. Szansą dla sektora jest długookresowa perspektywa wzrostu popytu krajowego ze względu na inwestycje infrastrukturalne, inwestycje w energetykę oraz politykę unijną promującą alternatywne źródła energii, w tym energetykę wiatrową. Poszczególne branże – odbiorcy produktów hutniczych - wykazują różne tendencje wzrostowe. Jedne znajdują się w fazie rozwoju, inne notują spadki, dlatego ważna jest dywersyfikacja produkcji i rynków zbytu, pozwalająca przetrwać okresy spowolnienia. Stawia to w lepszej sytuacji większe zakłady, które mogą szukać odbiorców poza rynkiem krajowym. Przedsiębiorcy zwracają uwagę na wysokie koszty materiałów i energii, trudności w egzekwowaniu należności, niedobór wykwalifikowanych kadry i konkurencję ze strony producentów z Azji i Europy.

Przedsiębiorstwa zmuszone są minimalizować niekorzystny wpływ na środowisko poprzez usprawnianie procesu produkcji przy jednoczesnym zachowaniu konkurencyjności. Huty współpracują w tym celu z uniwersytetami i instytutami badawczymi. W obliczu tych wyzwań i możliwości wzrasta znaczenie trafnej prognozy.

Ponadto produkcja hutnicza może podlegać wahaniom sezonowym, co również wymaga sprawdzenia.

To właśnie powyższe przesłanki oraz brak jak dotąd znanej autorowi analizy, która łączyłaby zagadnienie modelowania popytu i sprzedaży z sytuacją hutnictwa, wpłynęły na wybór tematu i sformułowane zagadnienia badawcze.

Pytania badawcze

Celem opracowania jest wyznaczenie optymalnej metody analizy przyszłych wielkości popytu i sprzedaży dla branży reprezentującej przemysł ciężki. Celem poznawczym jest przegląd i usystematyzowanie ilościowych modeli prognozowania oraz identyfikacja możliwych czynników wpływu. Wyodrębniono cel praktyczny, a mianowicie zdefiniowanie rekomendacji wdrożenia modelu przez przedsiębiorstwo, jako alternatywnej bądź równoległej metody prognozowania.

W opracowaniu badano, czy uwzględnienie w prognozie wskaźników koniunktury, dla przemysłu zależnego w dużym stopniu od wahań kondycji gospodarki, może polepszyć jej

jakość. Podjęto próbę weryfikacji, czy modele opisujące procesy stochastyczne mają zastosowanie w długoterminowym prognozowaniu wielkości sprzedaży. Wyznaczenie modelu wymaga identyfikacji wahań sezonowych oraz ustalenia wskaźnika koniunktury, który wyjaśniałby zmiany popytu.

Metody badawcze

Odpowiedzi na tak sformułowane pytania badawcze szukano na podstawie przeglądu literatury w zakresie metod prognozowania szeregów czasowych o dużej zmienności oraz doboru zmiennych w modelach prognostycznych. Wzięto pod uwagę metody klasyczne, modele opisujące procesy stochastyczne oraz modele ze zmiennymi ukrytymi. Przeanalizowano metody wyrównania sezonowego, pozwalające na dekompozycję szeregów.

Ważnym kryterium doboru jest cel modelu. Rozważano zatem przede wszystkim metody, które pozwalają na wydłużenie horyzontu prognozy, uwzględnienie kondycji gospodarki jako zmiennej wpływu oraz uwzględnienie wpływu niemierzalnych czynników. Porównano publikacje dotyczące metod prognozowania stosowanych w przemyśle ciężkim (m.in. Briffaut i Lallement 2010), prognozowania dla rynku dóbr przemysłowych (m.in. Rippe 1976), prognozowania zmiennych makroekonomicznych i cykli koniunkturalnych (m.in. Bernardelli 2013), prognozowania sprzedaży dóbr o okresach niskiego popytu.

Przy doborze zmiennych kierowano się popularnością wykorzystania danej zmiennej w modelach prognozowania popytu i sprzedaży lub informacją od przedsiębiorstwa o jej oczekiwanym powiązaniu z badanym zjawiskiem. Identyfikacji czynników wpływu dokonano również na podstawie analizy rynku wyrobów hutniczych i otoczenia typowego reprezentanta branży. W szczególności badano możliwość włączenia wskaźników wyprzedzających.

Sformułowane zagadnienie i związane z nim pytania badawcze wymagają doboru reprezentatywnych danych. W tym celu poszukiwano firm reprezentujących sektor hutnictwa. Struktura rynku to kilkanaście dużych zakładów i kilkadziesiąt mniejszych. W badanym okresie na rynku funkcjonowały trzy duże spółki o łącznym udziale w całkowitej produkcji wynoszącym niemal 70%. Udało się pozyskać dane od jednej z nich. Biorąc pod uwagę jej wielkość i strukturę rynku przyjęto, że dane są reprezentatywne dla sektora.

Dane przygotowano do badania poprzez sprawdzenie ich jakości, w tym wartości brakujących i odstających. Wybrano linie produktowe o największym znaczeniu z punktu widzenia przedsiębiorstwa. Szeregi czasowe dla różnych grup produktowych kształtowały się odmiennie i wymagałyby innego modelu. Ma to związek ze zróżnicowaną kondycją

przemysłów – odbiorców. Przygotowanie danych wymagało identyfikacji wahań sezonowych. Spośród dwóch procedur wyrównania sezonowego, X-12-ARIMA i TRAMO/SEATS, jedynie ta druga pozwoliła na wyznaczenie szeregu o zadowalającej jakości. Wykorzystano go w dalszej analizie.

Poza użytecznością modeli potwierdzoną w podobnych badaniach, ich selekcji dokonano kierując się możliwością uwzględnienia wskaźnika koniunktury (model ARIMAX) lub ukrytych czynników wpływu (model ukrytych łańcuchów Markowa - HMM). Intersujące wydaje się porównanie obu prognoz, ze względu na odmienne założenia modeli.

Zauważono, że w badanym szeregu dla lat 2004 – 2015, około roku 2009 występuje istotny spadek popytu, który może oznaczać zmianę strukturalną. Spowodowało to, że niektóre warianty wyznaczano dla skróconego szeregu, aby uzyskać stacjonarność. Dla wybranych metod przyjęto zasadę przeprowadzenia prognozy dla 6, 12 lub 18 obserwacji. Ma to związek z niemożnością wyznaczenia większego zbioru testowego dla 144 obserwacji, przy występującej możliwej zmianie strukturalnej.

Porównania modeli prognostycznych dokonano na podstawie miar błędów prognozy *ex post* oraz kryteriów informacyjnych, przyjmując kryterium minimalizacji obu wielkości. Hipotezy testów statystycznych weryfikowano na poziomie istotności 0,05, stosując więcej niż jeden test tam, gdzie to możliwe. Dodatkowo dla każdego modelu przeprowadzono symulację polegającą na wygenerowaniu losowych szeregów i zweryfikowaniu różnic błędów i kryteriów informacyjnych między modelami. Brak satysfakcjonującego rezultatu byłby przesłanką do rewizji modelu i parametrów. W literaturze niewiele jest uniwersalnych wskazówek co do wielkości próby. W opracowaniu zdecydowano o wyborze 3000 powtórzeń jako wystarczających, uprzednio sprawdzając, że zwiększanie próby w porównaniu do 1000 powtórzeń nie spowodowało znaczącej zmiany rezultatu, co jest praktyką proponowaną przez niektórych autorów. Pozytywny wynik symulacji dla wystarczającej liczby powtórzeń daje podstawy do uogólnienia rezultatu.

Dodatkowo przeprowadzono analizę porównawczą uzyskanych wyników w kontekście dokonań innych autorów. Uzyskanie prognoz o istotnie niższej jakości lub mniejszej dokładności byłoby przesłanką do rewizji modelu i zmiennych, czemu miał służyć ten etap.

Zgodnie z przyjętą procedurą badawczą, akceptacja modelu na tym poziomie daje podstawy do zaprezentowania go przedsiębiorstwu i uzyskania informacji zwrotnej. Dotyczy ona użyteczności prognozy, łatwości interpretacji, a także ustalenia akceptowalnego błędu. Niespełnienie warunku akceptowalności prognozy spowodowałoby jej odrzucenie lub rewizję

modelu. Tak przeprowadzone postępowanie doprowadziło do sformułowania rezultatu i oceny stopnia realizacji problemu badawczego.

Dobór materiałów

Doboru literatury dokonano na podstawie kryterium podobieństwa branży, dziedziny prognozowania, potencjalnych czynników wpływu. Korzystano przy tym z klasycznych publikacji odnoszących się do teorii popytu i podaży (Begg i in. 2003), metod prognozowania (m.in. Zeliaś i in. 2003, Cieślak i in. 2011), modeli ze zmiennymi ukrytymi (m.in. Baum i Eagon 1967, Schrodt 2000, Zwiernik 2005, Cappé i in. 2005), metod identyfikacji sezonowości (m.in. Gomez i Maravall 1996, Grudkowska i Paśnicka 2007), zarządzania procesem prognostycznym w firmie (Waters 2002, Rutkowski i in. 2005), stosowania wskaźników wyprzedzających (Szeplewicz 2011). Analiza otoczenia sektora wymagała przeglądu czasopism i publikacji branżowych (np. przygotowywanych przez Hutniczą Izbę Przemysłowo – Handlową, Związek Kuźni Polskich), raportów ówczesnego Ministerstwa Gospodarki, artykułów prasowych, danych Głównego Urzędu Statycznego i OECD.

Analizy danych dokonano przy pomocy oprogramowania Gretl, R i JDemetra+. JDemetra+ została wprowadzona przez Eurostat we współpracy z Narodowym Bankiem Belgii i służy do analizy i eliminacji wpływów sezonowych w szeregach czasowych. W badaniu korzystano z oprogramowania do wyznaczenia modeli X-12-ARIMA i TRAMO/SEATS i przeprowadzenia analizy porównawczej.

Rezultaty badania

Wyznaczono prognozy na podstawie ARIMAX ze wskaźnikiem koniunktury oraz na podstawie modelu ze zmiennymi ukrytymi. Wybrane metody są z różnym skutkiem stosowane w prognozowaniu procesów gospodarczych. Zbadano jakość prognoz i porównano ograniczenia metod. Uwzględniając szereg kryteriów walidacji modeli (testy statystyczne, symulacja wartości, miary błędów, użyteczność) zaproponowano zastosowanie wybranych wariantów przez przedsiębiorstwo i włączenie do aktualnego podejścia do planowania sprzedaży.

W kontekście badanego zjawiska uzasadnienie ma wybór metodologii ARIMA ze zmienną objaśniającą, która obrazuje sumaryczny wpływ niemierzalnych czynników. Zmiennej szukano pośród szeregu dostępnych wskaźników koniunktury. Na podstawie miar prognozy

ex post jako najlepsze wybrano wskaźnik wyprzedzający koniunktury (WWK), publikowany przez Biuro Inwestycji i Cykli Ekonomicznych oraz wskaźnik OECD dla krajów Unii Europejskiej. Uwzględnione razem w prognozie wnoszą informacje o stanie bieżącym oraz o potencjalnym kształtowaniu się koniunktury ze względu na własności wyprzedzające. Dodatkowo wybór wskaźnika dla Europy jest zgodny z faktyczną strukturą odbiorców firmy. Rezultat należałoby monitorować i potwierdzić dla dłuższego horyzontu czasowego. Poprawa w porównaniu do modelu ARIMA występuje jedynie dla wybranych miar błędów, jednak użycie wskaźników jest uzasadnione ich własnościami wyprzedzającymi oraz dążeniem do uniezależnienia prognozy wyłącznie od historycznych wartości. Na podstawie symulacji wykazano przewagę ARIMAX dla długiego horyzontu czasowego oraz potwierdzono, że poprawa uzyskana dzięki użyciu wskaźników ma charakter nieprzypadkowy.

Alternatywą dla ARIMAX jest model ukrytych łańcuchów Markowa, który uwzględnia występowanie niejawnych czynników wpływu. Pozwala na modelowanie czynnika losowego. Model umożliwia wyznaczenie kierunku kształtowania się zjawiska w przyszłości i jego użycie jest zasadne w planowaniu długookresowym. Przeprowadzona symulacja potwierdziła zadowalający wynik modelu dwustanowego pierwszego rzędu, a wyznaczone stany mają odniesienie do rzeczywistych zmian PKB w Polsce w badanym okresie.

Zarówno najlepszy model ARIMAX jak i dwustanowy model Markowa wyznaczyły umiarkowane średnie miesięczne wartości prognozy dla badanego okresu, przy czym, ze względu na swoją konstrukcję, pierwszy model wyznaczył konkretne wartości, a drugi zaokrąglone. Z uwagi na te różnice pominięto porównanie miar błędów prognoz, a jedynym kryterium porównawczym jest ocena przedsiębiorstwa. Dla HMM wyznaczono odrębny system oceny modelu, polegający na porównaniu z losowo wygenerowanymi szeregami. Argumentem za stosowaniem metod równoległe jest ich niezależność, polegająca na przyjęciu odmiennych założeń.

Znaczenie teoretyczne i praktyczne pracy

Pod względem teoretycznym opracowanie stanowi wkład w analizę otoczenia firm sektora, opisując zagrożenia i szanse. Pod uwagę wzięto kondycję powiązanych przemysłów. Ponadto rozszerza dotychczasowe badania popytu, sprzedaży i sezonowości o analizę modeli różnych typów dla danych reprezentanta przemysłu hutniczego. Rezultaty uzyskane dla modelu ARIMAX charakteryzują się niewielkimi, kilkuprocentowymi różnicami błędów

w porównaniu do ARIMA, a prognozę cechuje duża dokładność dla krótkiego horyzontu czasowego. W przypadku kilku autorów lepiej udało się dopasować wskaźnik do badanego zjawiska (np. stopa bezrobocia dla pomiaru PKB, wskaźnik nastrojów gospodarczych dla pomiaru bezrobocia – m.in. Bielak 2010, Ďurka i Pastoreková 2012). Trudniej o takie porównanie w przypadku procesów Markowa, gdyż ocena zależy od przyjętego systemu, np. kładąc nacisk na wskazania fałszywie negatywne lub dodatnie. Jak wspomniano, zauważono też podobieństwa w kształtowaniu się stanów jednego z wyznaczonych modeli Markowa w odniesieniu do rzeczywistych zmian PKB w Polsce, chociaż szereg jest zbyt krótki, aby móc twierdzić o długookresowej zależności. Podobnie innym autorom (m.in. Hamilton 1990) udało się z dużą dokładnością wyznaczyć punkty zwrotne koniunktury dla Stanów Zjednoczonych, zgodne z danymi publikowanymi przez National Bureau of Economic Research.

Znaczenie praktyczne przejawia się w wyznaczeniu modelu dla reprezentanta przemysłu ciężkiego i przedstawienia możliwości jego zastosowania. Wyznaczenie prognozy dla modelu ARIMAX może być podstawą opracowania celów strategicznych, realizowanych poprzez krótko- i średniookresowe działania. Celem takim mogłaby być próba umocnienia pozycji konkretnego przedsiębiorstwa na rynku krajowym, dopasowanie oferty do struktury odbiorców, poszukiwanie nowych rynków zbytu. Łącznie z działaniami w zakresie rewizji sfery organizacyjnej, racjonalizacji zatrudnienia, systemu płac oraz modernizacji maszyn, modele mogłyby się przyczynić do szybszego dostosowania do nowych warunków rynkowych.

Zaproponowane metody mogą stanowić wkład w ocenę sytuacji otoczenia przez przedsiębiorstwo i zostać włączone w dotychczasowy proces prognostyczny. Sugerowanym rozwiązaniem byłoby zaangażowanie ekspertów w dobór zmiennych objaśniających lub w szacowanie parametrów prognozy ilościowej.

Ograniczenia procedury badawczej

Przedstawiona procedura badawcza ma pewne ograniczenia i wymaga przyjęcia określonych założeń. W opracowaniu postawiono pytanie o możliwość wydłużenia horyzontu prognozy w hutnictwie. Przeprowadzona analiza daje odpowiedź na kwestie interesujące badaną firmę - reprezentanta sektora. Długość szeregu nie uprawnia do wyciągnięcia wniosku

o długoterminowych zależnościach między wskaźnikiem a badanym zjawiskiem. Brak danych po 2015 roku powoduje, że rezultat trzeba odnieść do sytuacji przeszłej.

Badanie przeprowadzono na podstawie danych jednego z większych przedstawicieli hutnictwa żelaza i stali w Polsce, gdzie struktura rynku to kilkanaście dużych hut oraz kilkadziesiąt małych i średnich zakładów. W badanym okresie przedsiębiorstwo odnotowało co najmniej 20% udział w rynku biorąc pod uwagę rozmiary produkcji. Wszystkie duże zakłady przeszły podobną, żmudną drogą dostosowania do gospodarki rynkowej, choć występują różnice w strukturze organizacyjnej i udziale kapitału zagranicznego. Na tej podstawie przyjęto, że wielkość sprzedaży na podstawie danych przedsiębiorstwa jest reprezentatywna dla badanego sektora.

W opracowaniu wielkość popytu mierzona jest wielkością sprzedaży, a zatem mowa o popycie zrealizowanym. Zaznaczyć należy również, że badano sprzedaż dla wybranych grup produktowych, w związku z różnym przeznaczeniem asortymentu.

W przypadku modelu ARIMAX brak jest długookresowej kointegracji między szeregiem a badanymi wskaźnikami. Dobór indeksu prezentującego kondycję branży hutniczej mógłby pozytywnie wpłynąć na jakość prognozy. Słabością zaproponowanych modeli Markowa jest wyznaczenie uogólnionych wartości popytu. W modelu dwustanowego analizie podlega względnie krótki szereg czasowy, który nie daje podstaw do potwierdzenia długookresowej zdolności modelu do identyfikacji punktów zwrotnych.

Przedstawione ograniczenia wynikają zatem głównie z dostępu do najnowszych danych oraz danych dla większej liczby podmiotów.

Możliwa kontynuacja badań

W badaniu nie wykorzystano w sposób bezpośredni informacji o klientach i regionach geograficznych. Na tej podstawie można rozszerzyć analizę o konkretnych odbiorców i rynki zbytu. Ponadto badanie warto powtórzyć dla innych grup produktowych, gdzie występują inne tendencje. Możliwa jest kontynuacja prac badawczych dla innych przedsiębiorstw, co pozwoliłoby zweryfikować wpływ różnic związanych z lokalizacją czy stylem zarządzania. Poszukując wskaźnika koniunktury, wzięto pod uwagę te powszechnie dostępne. Może zatem istnieć wskaźnik, który lepiej wyjaśnia wahania popytu i sprzedaży w hutnictwie.

Bibliografia (wybór)

1. Baum, L.E., Eagon, J.A. (1967) *An inequality with applications to statistical estimation for probabilistic functions of markov processes and to a model of ecology*. Bulletin of the American Mathematicians Society, nr 73, str. 360-363.
2. Begg, D., Fisher, S., Dornbusch, R. (2003) *Mikroekonomia*. Polskie Wydawnictwo Ekonomiczne, Warszawa
3. Bernardelli, M. (2013) *Nieklasyczne modele Markowa w analizie cykli koniunktury gospodarczej w Polsce*. Roczniki Kolegium Analiz Ekonomicznych, nr 30.
4. Bielak, J. (2010) *Prognozowanie ryku pracy woj. lubelskiego z wykorzystaniem modeli ARIMA i ARIMAX*. Barometr Regionalny, nr 1 (19).
5. Briffaut, J.P., Lallement, P. (2010) *Volatility Forecasting of Market Demand as Aids for Planning Manufacturing Activities*. Service Science & Management, nr 3, str. 383-389.
6. Cappé O., Moulines E., Rydén T. (2005) *Inference in hidden Markov models*. Springer Series in Statistics.
7. Cieślak, M. i in. (2011) *Prognozowanie gospodarcze. Metody i zastosowania*. PWN, Warszawa.
8. Ďurka, P., Pastoreková, S. (2012) *ARIMA vs. ARIMAX – which approach is better to analyze and forecast macroeconomic time series?* Proceedings of 30th International Conference Mathematical Methods in Economics.
9. Gómez, V., Maravall, A. (1996) *Programs TRAMO (Time Series Regression with Arima noise, Missing observations, and Outliers) and SEATS (Signal Extraction in Arima Time Series). Instruction for the User*. Bank of Spain, nr 9628.
10. Grudkowska, S., Paśnicka, E. (2007) *X-12-ARIMA I TRAMO/SEATS – empiryczne porównanie metod wyrównania sezonowego w kontekście długości próby*. Narodowy Bank Polski, Materiały i studia, nr 220.
11. Hamilton, J.D. (1990) *Analysis of time series subject to changes in regime*. Journal of econometrics, nr 45, str. 39-70.
12. Rutkowski, K. i inni. (2005) *Logistyka dystrybucji*. Szkoła Główna Handlowa, Warszawa.
13. Schrodtt, P.A. (2000) *Forecasting conflict in the Balkans using hidden Markov models*. Paper presented at the American Political Science Association meetings, Washington.
14. Szeplewicz, K. (2011) *Wskaźniki wyprzedzające koniunktury - analiza ekonometryczna*. Prace i materiały Instytutu Rozwoju Gospodarczego, IRG SGH, Warszawa, nr 87.
15. Szulc, W. (2014) *Transformacja polskiego hutnictwa żelaza do gospodarki wolnorynkowej (z uzupełnieniami)*. Prace Instytutu Metalurgii Żelaza. Monografie, nr 6.
16. Waters, D. (2002) *Operations Management*. Pearson Education Limited, Essex
17. Zeliaś, A., Pawełek, B., Wanat, S. (2003) *Prognozowanie ekonomiczne: teoria, przykłady, zadania*. Wydawnictwo Naukowe PWN, Warszawa.
18. Zwiernik, P.W. (2005) *Wstęp do ukrytych modeli Markowa i metody Bauma-Welcha*. <http://www.mimuw.edu.pl/~pzwiernik/docs/hmm.pdf>.