

**Jan Acedański**

Uniwersytet Ekonomiczny w Katowicach

# **KRÓTKOTERMINOWE PROGNOZY DYNAMIKI WYNAGRODZEŃ W POLSCE**

## **Wprowadzenie**

Wynagrodzenia są jedną z najważniejszych kategorii makroekonomicznych. Ich wysokość ma istotny wpływ na funkcjonowanie wielu elementów systemu gospodarczego danego kraju. Przede wszystkim wysokość wynagrodzeń determinuje wysokość dochodów dużej grupy gospodarstw domowych, nie tylko gospodarstw osób pracujących, ale częściowo utrzymujących się z emerytur i rent, których wysokość w pewnej części jest uzależniona od wysokości płac. W efekcie zaś wynagrodzenia oddziałują m.in. na poziom popytu wewnętrznego, co z kolei przekłada się na dynamikę PKB lub presję inflacyjną, także w odniesieniu do cen aktywów finansowych. Płace będące kluczową kategorią rynku pracy istotnie wpływają na decyzje dotyczące popytu i podaży pracy. Z tych też przyczyn prowadzenie skutecznej polityki gospodarczej na szczeblu centralnym wymaga prognozowania dynamiki wynagrodzeń. Dotyczy to zarówno polityki pieniężnej oraz fiskalnej, jak i społecznej. W pierwszym przypadku wynika to przede wszystkim z wpływu, jaki ma dynamika wynagrodzeń na poziom presji inflacyjnej. W odniesieniu do polityki fiskalnej poziom płac ma duże znaczenie dla kształtowania się dochodów budżetowych. W zakresie polityki społecznej istotną rolę odgrywa natomiast fakt, iż dynamika wynagrodzeń determinuje dochody ludności i wysokości wielu świadczeń. We wszystkich tych przypadkach konieczne jest prognozowanie wynagrodzeń dla średnich oraz długich horyzontów, a więc co najmniej na 1-3 lata wprzód.

W pracy podjęto próbę prognozowania dynamiki wynagrodzeń w Polsce dla średniego horyzontu równego 1 lub 2 lata. Stosowano w tym celu modele wskaźników wyprzedzających [Cieślak, red., 2001; Dittmann, 2003; Białowski, Żochowski, 2006]<sup>1</sup>. Poszukiwano więc takich indywidualnych zmiennych bądź ich liniowych kombinacji, których zmiany występowały z odpowiednim wyprze-

---

<sup>1</sup> Alternatywną metodę prognozowania wynagrodzeń proponuje m.in. E. Szabela-Pasierbińska [2011].

dzeniem w stosunku do zmian wynagrodzeń<sup>2</sup>. W badaniu wykorzystano cztery różne miary dynamiki średnich miesięcznych wynagrodzeń w Polsce. Wskaźniki wyprzedzające były wybierane ze zbioru 190 zmiennych złożonych głównie z wyników ankietowych badań koniunktury prowadzonych przez GUS. Zmienne użyte w badaniu miały charakter miesięczny i obejmowały okres 1.2000-9.2012. Jako miarę dokładności prognoz wybrano błąd średniokwadratowy prognoz wygasłych. Wyniki dla modeli wskaźników wyprzedzających porównywano z rezultatami uzyskanymi na podstawie modeli naiwnych oraz autoregresyjnych.

Z problemem wyboru najlepszego modelu prognostycznego wiążą się zagadnienia wyboru zmiennych do modelu oraz długości próby przeznaczonej do estymacji jego parametrów. Druga z tych kwestii nabiera szczególnego znaczenia w warunkach niestabilności relacji pomiędzy zmiennymi wchodzącymi w skład modelu, przy założeniu, że szacowane parametry są traktowane jako stałe. W takiej sytuacji wydłużanie próby niekoniecznie prowadzi do zwiększania dokładności prognoz. W przypadku gdy do oceny modeli wykorzystuje się prognozy wygasłe, pojawia się problem malejącej liczby prognoz wygasłych przy zwiększaniu się liczby obserwacji przeznaczonych do estymacji parametrów. Najprostszym rozwiązaniem byłoby tutaj wykorzystanie do porównywania modeli jedynie wspólnej dla wszystkich modeli części prognoz wygasłych. Takie podejście jest jednak możliwe jedynie w przypadku dysponowania odpowiednio długą próbą badawczą, co w polskich warunkach nie jest zwykle możliwe do osiągnięcia.

W związku z tym w pracy zaproponowano nową procedurę pozwalającą na porównanie zdolności prognostycznych *ex post* modeli szacowanych na podstawie prób o różnych długościach. Zakłada ona, że możliwe jest prognozowanie błędów prognoz wygasłych. Przykładowo, jeżeli dany jest ciąg błędów prognoz wygasłych uzyskanych z modelu A estymowanego na dłuższej próbie, które mają być porównywane z prognozami uzyskanymi z modelu B szacowanego na podstawie próby krótszej, to najpierw jest szacowana zależność pomiędzy błędami z obu modeli na wspólnym dla obu modeli zbiorze prognoz wygasłych, a następnie zależność tę przenosi się na brakujące okresy, dla których wyznacza się prognozowane błędy z modelu A. W efekcie dla modelu A uzyskuje się ciąg błędów prognoz o takiej samej długości jak dla modelu B, na podstawie którego można wyznaczać i porównywać wartości pewnej funkcji straty będącej miarą dokładności prognoz wygasłych, np. funkcji błędu średniokwadratowego. Niektóre argumenty tej funkcji dla modelu A są prognozami, z którymi jest związany pewien stopień niepewności, dlatego obliczonym na ich podstawie wartościom funkcji straty towarzyszy pewien błąd. Przy podejmowaniu decyzji odnośnie do wyboru modelu badacz powinien w związku z tym brać pod uwagę nie tylko wartości funkcji straty, ale również ocenę precyzji ich oszacowania.

<sup>2</sup> Nieco inne podejście do prognozowania przy użyciu wskaźników wiodących można znaleźć w pracy: G. Szafrński [2011].

Praca składa się z czterech części. W pierwszej scharakteryzowano mierniki wynagrodzeń, będące zmiennymi prognozowanymi w badaniu oraz zbiór potencjalnych wskaźników wyprzedzających, z którego wybierano zmienne do modeli prognostycznych. W części drugiej omówiono sposób budowy i estymacji modeli wskaźników wyprzedzających. Następnie szczegółowo scharakteryzowano procedurę porównywania zdolności prognostycznych modeli. W części czwartej przedstawiono wyniki badań.

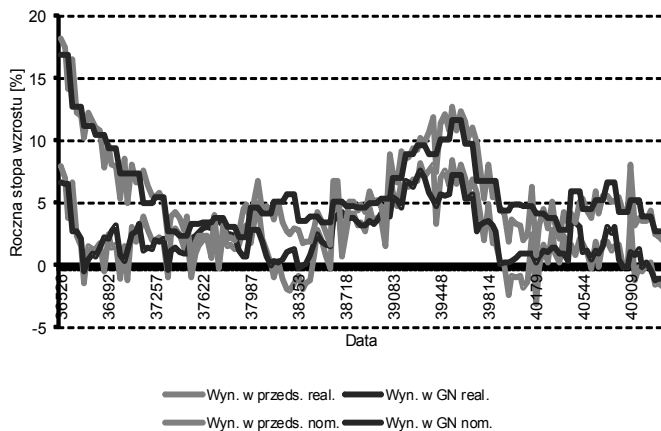
## 1. Opis zmiennych

W badaniu wykorzystano dwie podstawowe zmienne opisujące poziom wynagrodzeń w Polsce: przeciętne miesięczne wynagrodzenie w gospodarce narodowej oraz przeciętne miesięczne wynagrodzenie w sektorze przedsiębiorstw. Pierwsza zmienna jest publikowana co kwartał i obejmuje wynagrodzenia w większości podmiotów gospodarki narodowej, również tych, w których liczba pracujących nie przekracza 9 osób. Druga miara jest mierzona z częstotliwością miesięczną, przy czym dotyczy wynagrodzeń w sektorze przedsiębiorstw – w podmiotach, w których liczba pracujących jest większa niż 9 osób [*Zasady metodyczne...*, 2008].

Wynagrodzenia w gospodarce narodowej jako zmienną kwartalną zamieniono na zmienną miesięczną, przyjmując, że jej wartości w każdym miesiącu danego kwartału były sobie równe. Obie zmienne zostały wyrażone w postaci rocznych indeksów dynamiki jako miesięczne zmiany w stosunku do analogicznego miesiąca roku poprzedniego, a następnie poddane procedurze odsezonowania w programie Demetra Plus.

Oprócz dynamiki wynagrodzeń nominalnych, analizowano dynamikę zmiennych realnych stanowiących różnicę pomiędzy procentową dynamiką wynagrodzeń nominalnych oraz roczną stopą inflacji CPI. Dynamikę wszystkich prognozowanych zmiennych ilustruje rys. 1.

Do zbioru potencjalnych zmiennych objaśniających wzięto przede wszystkim zmienne wskazujące na stan przyszłej koniunktury w gospodarce, ponieważ przyjęto dość długi horyzont prognoz. Podstawową grupę zmiennych objaśniających stanowiły wyniki comiesięcznego badania ankietowego koniunktury w przemyśle publikowane przez GUS. Pod uwagę brano odpowiedzi na pytania dotyczące przewidywań: ogólnej sytuacji gospodarczej, portfela zamówień, produkcji, zatrudnienia oraz cen sprzedaży wyrobów. Uwzględniano wyniki zbiorcze dla wszystkich ankietowanych przedsiębiorstwa, jak i w podziale na wielkość przedsiębiorstwa oraz profil działalności. W efekcie z każdym z pięciu pytań były związane 33 zmienne. Łącznie w tej grupie znalazło się 165 zmiennych oznaczanych w dalszej części pracy X1\_1, X1\_2, ..., X1\_33, X2\_1, ..., X2\_33, ..., X3\_1, ..., X5\_33.



Rys. 1. Dynamika prognozowanych zmiennych

Drugą grupę zmiennych stanowiły zharmonizowane roczne wskaźniki inflacji konsumenckiej w podziale na 12 głównych grup towarów publikowane przez Eurostat. Zmienne te oznaczano jako  $X6\_1$ ,  $X6\_2$ , ...,  $X1\_13$ . Trzecia grupa składała się z pojedynczych zmiennych opisujących sytuację na rynku pracy, a także zmiennych uważanych na wskaźniki przyszłej koniunktury. Grupa ta liczyła 12 zmiennych: przeciętne zatrudnienie w sektorze przedsiębiorstw, stopę bezrobocia rejestrowanego, wskaźnik cen produkcji sprzedanej przemysłu, indeks produkcji przemysłowej, oczekiwania inflacyjne, indeks WIG20, podaż pieniądza M3, stopę WIBOR3M, indeks menadżerów logistyki PMI oraz trzy indeksy IFO, będące przewidywaniami koniunktury w Niemczech. Zmienne te indeksowano jako  $X7\_1$ ,  $X7\_2$ , ...,  $X7\_13$ . Tam gdzie było to uzasadnione, zmienne te zostały wyrażone w postaci rocznych indeksów dynamiki oraz odsezonowane. Zbiór potencjalnych zmiennych objaśniających łącznie składał więc ze 190 miesięcznych zmiennych obserwowanych w okresie 1.2000-9.2012. Szeregi czasowe liczyły więc po 153 obserwacje. W załączniku zamieszczono szczegółowe opisy zmiennych objaśniających.

## 2. Modele prognostyczne

Jako wskaźniki wyprzedzające były wykorzystywane zmienne, które w największym stopniu wyjaśniały przyszłą dynamikę zmiennych prognozowanych. W tym celu dla każdego analizowanego horyzontu prognozy  $h$  budowano modele postaci:

$$Y_{t+h} = \alpha_0 + \alpha_1 Y_t + \alpha_2 X_{i,t} + \xi_{t+h}, \quad (1)$$

gdzie:

$Y_t$  jest zmienną prognozowaną,

$X_{i,t}$  jest zmienną objaśniającą,

$\alpha$  oznaczają parametry,

$\xi$  jest składnikiem losowym.

Rozpatrywano również modele bez części autoregresyjnej, a więc gdy  $\alpha_1 = 0$ . Nie brano pod uwagę żadnych opóźnień zmiennych objaśniających, aby nie komplikować modeli i ograniczać ich dużą liczbę. Poza tym przy dłuższych horyzontach prognozy, dodatkowe opóźnienia raczej nie miałyby większego znaczenia. W pracy rozważano modele złożone tylko z jednej zmiennej objaśniającej, porównując ze sobą wszystkie możliwe modele – łącznie 380. Ich parametry modeli szacowano klasyczną metodą najmniejszych kwadratów.

Alternatywę dla omówionych modeli wskaźników wyprzedzających stanowiły modele prognoz naiwnych oraz modele autoregresyjne AR(1). W pierwszym przypadku przyjmowano po prostu  $Y_{t+h} = Y_t$ . W drugim szacowano dwie wersje modeli autoregresyjnych postaci:

$$Y_t = \gamma_0 + \gamma_1 Y_{t-3} + \xi_{Y,t} \quad \text{oraz} \quad Y_t = \gamma_0 + \gamma_1 Y_{t-1} + \xi_{Y1,t}. \quad (2)$$

Pierwszą wersję stosowano przy prognozowaniu przeciętnych wynagrodzeń w gospodarce narodowej, które są publikowane raz na kwartał. W przypadku wynagrodzeń w sektorze przedsiębiorstw korzystano z drugiej formuły. Na podstawie oszacowanych modeli (2) obliczano rekurencyjnie prognozy dla zadanego horyzontu.

### 3. Wybór najlepszego modelu

Zdolności prognostyczne modeli oceniano poprzez analizę błędów średniokwadratowych ciągów prognoz wygasłych. Prognozy te obliczano stosując standardową procedurę przesuwanych okien obserwacyjnych o stałej długości  $n$ . Niech  $T$  oznacza łączną liczbę obserwacji, jaką dysponuje badacz. Do szacowania parametrów modeli w pierwszej kolejności wykorzystywano obserwacje o numerach 1, 2, ...,  $n$ . Należy jednak mieć na uwadze, iż efektywnie liczba obserwacji przy estymacji była równa  $n - h$ , ze względu na przesunięcie czasowe pomiędzy zmienną prognozowaną a zmiennymi egzogenicznymi. Korzystając z oszacowanych modeli, były obliczane prognozy na okres  $n + h$ . Następnie przesuwano próbę o jeden okres wprzód i obliczano prognozy na okres  $n + 1 + h$ . Procedurę

kontynuowano do momentu obliczenia prognoz na okres  $T$ . W efekcie uzyskiwano ciąg  $s = T - n - h$  prognoz, które porównywano z faktycznymi realizacjami zmiennej prognozowanej i obliczano wartości funkcji straty – w pracy funkcji błędu średniokwadratowego.

Przy ustalonej długości próby  $n$  porównanie wartości funkcji straty dla różnych modeli, uzupełnione ewentualnymi testami statystycznymi zdolności prognostycznych [Giacomini, White, 2006; Todd, McCracken, 2011], pozwala na wybór modelu najlepszego dla celów predykcji. Problem powstaje w sytuacji, gdy długość próby  $n$  nie jest ustalona i badacz chce dobrać ją tak, by maksymalizować zdolności prognostyczne modeli. Takie podejście jest szczególnie uzasadnione w sytuacji, gdy zachodzi podejrzenie niestabilności relacji pomiędzy zmienną prognozowaną a zmiennymi objaśniającymi, a więc gdy zwiększanie długości próby może pogarszać zdolności prognostyczne modeli. Porównywanie wartości funkcji straty, obliczanych na podstawie prognoz wygasłych z różnych okresów, nie zawsze jest uzasadnione, nawet gdy okresy te częściowo się pokrywają. Może się bowiem okazać, iż okresy te różnią się zdecydowanie ze względu na przebieg prognozowanego zjawiska właśnie w części niebędącej częścią wspólną i model, który cechował się dużą dokładnością prognoz w jednym okresie, niekoniecznie musi sprawdzać się także w drugim okresie. Jest to tym bardziej prawdopodobne, im mniejsza jest liczba porównywanych prognoz wygasłych.

W pracy zaproponowano podejście, które pozwala na porównywanie zdolności prognostycznych modeli szacowanych na podstawie prób o różnych długościach przy pomocy analizy dokładności prognoz wygasłych. Zakłada się w nim, że możliwe jest prognozowanie błędów prognoz dla brakujących okresów. Wykorzystuje się przy tym fakt, że okresy weryfikacji prognoz estymowanych na próbach dłuższych zawierają się w okresach weryfikacji modeli opierających się na krótszych próbach. Część wspólną tych dwóch okresów wykorzystuje się do oszacowania zależności pomiędzy błędami prognoz modeli z obu grup. Zależności te wraz z obserwowanymi błędami dla modeli opartych na krótszych próbach pozwalają na predykcję błędów prognoz modeli wykorzystujących próby dłuższe na wcześniejsze okresy, dla których nie jest możliwe wyznaczenie prognoz. W ten sposób dla obu grup modeli badacz dysponuje taką samą liczbą błędów prognoz wygasłych obliczonych dla tego samego okresu. Należy jednak podkreślić, iż część z nich jest prognozami, a więc wielkościami niepewnymi. W związku z tym, z obliczonymi na ich podstawie wartościami funkcji straty są związane pewne miary niepewności, które należy brać pod uwagę w procesie wyboru najlepszego modelu.

Opisana powyżej ogólna idea podejścia może być zrealizowana na kilka różnych sposobów. Poniżej scharakteryzowano szczegółowo podejście rekurencyjne do predykcji błędów prognoz, które zostało zastosowane w pracy.

Niech  $M$  oznacza liczbę wszystkich porównywanych modeli, których parametry są szacowane na podstawie  $n_1 < n_2 < \dots < n_k$  obserwacji. Opierając

się na tych modelach uzyskano ciągi prognoz wygasłych liczące odpowiednio  $s_1 > s_2 > \dots > s_K$  elementów. Niech:

$$u_i^{(mk)} = Y_{T+1-i} - \hat{Y}_{T+1-i}^{(mk)},$$

gdzie:

$i = 1, 2, \dots, s_k$  oznacza błąd prognozy wygasłej z okresu  $T + 1 - i$  uzyskanej na podstawie modelu  $m$ ,

$m = 1, 2, \dots, M$ , którego parametry szacowano na podstawie  $n_k$  obserwacji,

$k = 1, 2, \dots, K$ .

Należy zwrócić uwagę, iż w powyższym ujęciu błędy prognoz są numerowane od końca, to znaczy błąd dla okresu  $T$  ma numer 1, dla okresu  $T - 1$  ma numer 2 itd.

Dla wszystkich modeli wartości funkcji straty  $g$  są obliczane na podstawie ciągów  $s_1$  błędów prognoz wygasłych. W przypadku modeli estymowanych na podstawie  $n_1$  obserwacji wartości wszystkich błędów są znane i dlatego możliwe jest bezpośrednio obliczenie:

$$g\left(\left\{u_i^{(m1)}\right\}_{i=1}^{s_1}\right),$$

gdzie:

$m = 1, 2, \dots, M$ .

Dla modeli opartych na  $n_2$  obserwacji znanych jest  $s_2$  błędów prognoz, a brakuje  $s_1 - s_2$  wartości błędów należy oszacować. W tym celu dla każdego ciągu prognoz  $\left\{u_i^{(m2)}\right\}_{i=1}^{s_2}$  budowano modele postaci:

$$u_i^{(m2)} = \beta_0 + \sum_{j=1}^l \beta_j u_i^{(mj1)} + \varepsilon_i^{(m2)}, \quad (3)$$

gdzie:

$i = 1, 2, \dots, s_2$ .

$\beta$  są nieznanymi parametrami szacowanymi klasyczną metodą najmniejszych kwadratów.

Na podstawie wyestymowanego modelu były wyznaczane prognozowane wartości błędów:

$$\hat{u}_i^{(m2)} = \hat{\beta}_0 + \sum_{j=1}^l \hat{\beta}_j u_i^{(mj1)}, \quad (4)$$

gdzie:

$i = s_2 + 1, \dots, s_1$ .

Ważnym problemem na tym etapie jest dobór zmiennych  $u^{(mj1)}$  do modeli. W przypadku dużej liczby modeli oraz mając na uwadze fakt, iż modele z obu grup różnią się jedynie liczbą obserwacji, na podstawie których były estymowane ich parametry, możliwe jest łatwe znalezienie modeli cechujących się bardzo podobnymi własnościami prognostycznymi w okresie od  $n_2 + h$  do  $n_2 + h + s_2$ . W pracy korzystano z modeli złożonych z  $l = 2$  zmiennych objaśniających. Jako



pierwszą wybierano tą, którą charakteryzowała najwyższa wartość współczynnika korelacji liniowej Pearsona ze zmienną prognozowaną. Drugą dobierano tak, aby maksymalizować współczynnik korelacji wielorakiej pomiędzy resztami  $u^{(m_2)}$  a  $u^{(m_1)}$  oraz  $u^{(m_2)}$ , dbając jednocześnie, aby współczynnik korelacji liniowej Pearsona pomiędzy  $u^{(m_1)}$  oraz  $u^{(m_2)}$  nie przekroczył z góry zadanego poziomu granicznego. W ten sposób zabezpieczano się przed nadmiernym dopasowaniem modelu opierającego się na dwóch współliniowych zmiennych. Jak pokazały wyniki badań, w zdecydowanej większości przypadków współczynniki determinacji tak stworzonych modeli przekraczały poziom 0,95.

Analogiczną procedurę stosowano do prognozowania brakujących błędów dla pozostałych grup modeli. Przykładowo dla modeli z grupy  $k$ -tej wykorzystywano obserwowane i prognozowane błędy z grupy  $k - 1$ . Alternatywą byłoby opieranie się przy prognozowaniu zawsze na obserwowanych błędach dla modeli z pierwszej grupy. Jednak w takim przypadku dość duża różnica w długościach prób stosowanych do estymacji parametrów mogłaby powodować, że trudno byłoby osiągnąć wysokie dopasowania równań postaci (3).

Ważnym etapem całej procedury jest oszacowanie miar dokładności obliczonych w powyższy sposób wartości funkcji straty. Przy założeniu normalności rozkładu składników losowych  $\varepsilon_i^{(mk)}$  prognozowane wartości błędów prognoz również miałyby rozkłady normalne, których macierze kowariancji można by w przybliżeniu wyznaczyć. Funkcja straty jest jednak zazwyczaj nieliniowa ze względu na błędy, które dodatkowo mogą być ze sobą silnie skorelowane, dlatego wyznaczenie wariancji obliczonych wartości funkcji straty przy pomocy wzorów analitycznych jest trudne.

Do oceny dokładności uzyskanych oszacowań przyjęto więc podejście symulacyjne. Utrzymując założenie o normalności rozkładu składników losowych równań (3), oszacowane parametry  $\hat{\beta}$  mają rozkłady normalne, których macierze kowariancji można analitycznie oszacować. Zakładając że rozkłady  $\hat{\beta}$  pochodzące z różnych równań są wzajemnie niezależne, dla wszystkich modeli losowano realizacje  $\hat{\beta}^{(q)}$ ,  $q = 1, 2, \dots, Q$ , obliczając odpowiadające im wartości funkcji straty. W efekcie otrzymano symulowany rozkład wartości funkcji straty dla każdego modelu. Jego odchylenie standardowe potraktowano jako miarę dokładności obliczonych oszacowań funkcji straty.

Ostatnim krokiem procedury był wybór modelu o najlepszych własnościach prognostycznych. Brano przy tym pod uwagę zarówno obliczone wartości funkcji straty, jak i miary precyzji ich oszacowania. W pracy przyjęto punkt widzenia ostrożnego badacza, który ma ograniczone zaufanie do zastosowanej procedury wyznaczania wartości funkcji straty. Jako najlepszy model wybierany był ten, który cechował się najniższą wartością funkcji straty powiększoną o trzykrotność jej błędu szacunku.



## 4. Wyniki badań

W pierwszej kolejności przeprowadzono tradycyjne badania zdolności prognostycznych modeli na podstawie prób różnej długości. Rozważano próby liczące  $n = 48, 60, 72, 84, 96$  oraz  $108$  obserwacji, których okres weryfikacji liczył odpowiednio  $s = 93, 81, 69, 57, 45$  oraz  $33$  miesiące. W rezultacie pierwiastki błędów średniokwadratowych dla każdej próby były obliczane na podstawie różnej liczby prognoz wygasłych. W tab. 1-2 przedstawiono wyniki dla wynagrodzeń w gospodarce narodowej przy horyzontach prognoz równych  $12$  i  $24$  miesiące, a także rezultaty dla prognoz z modeli naiwnych oraz autoregresyjnych oraz  $10$  najlepszych modeli wskaźników wyprzedzających, zaznaczając jednocześnie zmienne, które tworzyły dany model.

Tabela 1

Błędy RMSE w zależności od długości próby dla dynamiki nominalnych wynagrodzeń w GN dla  $h = 12$  miesięcy

$n$	48	60	72	84	96	108
$s$	93	81	69	57	45	33
Naiwne	2,72	2,89	3,10	2,93	3,07	2,13
AR(1)	3,41	3,48	3,86	3,10	2,26	1,82
LI	X1_16 2,16	X1_16 2,46	X4_2 2,61	X4_2 2,17	X6_7 1,12	X3_7 1,17
	X6_10 2,38	X4_29 2,63	X4_24 2,73	X5_23 2,30	X7_4 1,18	Y, X3_7 1,20
	X7_11 2,51	X4_5 2,63	X4_30 2,74	X5_16 2,33	X3_8 1,20	X4_24 1,20
	X2_16 2,55	X4_24 2,63	X4_29 2,75	X4_24 2,37	X4_24 1,23	Y, X6_12 1,21
	X3_6 2,56	X6_10 2,64	X1_16 2,75	X1_29 2,38	X6_6 1,25	Y, X4_24 1,22
	X3_24 2,57	Y, X6_7 2,69	X4_27 2,76	X4_27 2,39	X6_1 1,25	Y, X1_19 1,23
	X3_27 2,57	X4_13 2,70	X4_5 2,77	X3_16 2,43	X3_10 1,25	X4_2 1,24
	X4_24 2,57	X1_29 2,71	X4_28 2,77	X4_30 2,43	X1_19 1,29	Y, X4_2 1,24
	X3_26 2,57	X6_7 2,72	X3_16 2,81	X1_5 2,44	X4_27 1,34	Y, X3_10 1,24
	Y, X6_7 2,57	X4_2 2,72	X4_1 2,83	X5_26 2,45	Y, X3_19 1,35	X3_10 1,27

Analizując wyniki dla 12-miesięcznego horyzontu, można zauważyć, iż najlepsze modele wskaźników wyprzedzających generowały wyraźnie lepsze prognozy od modeli naiwnych oraz autoregresyjnych. Błąd RMSE prognoz naiw-

nych kształtował się w okolicach 3 p.p. w zależności od okresu ich weryfikacji. Jedynie w przypadku ostatniej grupy, dla której wyznaczono prognozy wygasłe na 33 ostatnich miesiący błąd ten był nieco wyższy niż 2 p.p. Modele autoregresyjne generowały prognozy obarczone zwykle jeszcze większymi błędami – pomiędzy 3 a 4 p.p. w pierwszych czterech okresach weryfikacji. Lepsze okazywały się jedynie w dwóch ostatnich grupach, gdzie RMSE kształtował się na poziomie mniej więcej 2 p.p. Tymczasem najlepsze modele wskaźników wiodących generowały błędy wyraźnie poniżej 3 p.p. W dwóch ostatnich okresach są one nieco wyższe niż 1 p.p.

Można zauważyć, że zdolności prognostyczne modeli mierzone wskaźnikiem RMSE są wyraźnie lepsze w dwóch ostatnich grupach, a więc dla modeli szacowanych na podstawie 96 oraz 108 obserwacji. Trudno jest jednak jednoznacznie stwierdzić, w jakim stopniu jest to rzeczywiście efekt lepszych oszacowań parametrów, a w jakim mniejszej zmienności prognozowanego zjawiska w ostatnich latach, na których opierała się wyłącznie weryfikacja modeli bazujących na najdłuższych próbach. Częściowo można to ocenić porównując dokładność prognoz naiwnych w różnych grupach, która odzwierciedla względną zmienność prognozowanego zjawiska. W przedostatnim okresie jest ona podobna do okresów poprzednich, co wskazuje, że wzrost zdolności prognostycznych w tym okresie można tłumaczyć większą precyzją estymacji parametrów modeli. W ostatnim okresie zmienność spada, co sprawia, że w świetle kryterium RMSE prognozowalność zwiększa się.

Wśród zmiennych, które cechowały się najlepszymi zdolnościami prognostycznymi dominują zmienne ilustrujące wyniki badań ankietowych koniunktury. Wśród 60 najlepszych modeli jedynie w 9 przypadkach w ich skład wchodzi inne zmienne, przede wszystkim mierniki inflacji. Trudno jest jednak o skonstruowanie syntetycznego rankingu zmiennych, gdyż ocena ich zdolności prognostycznej zmienia się w zależności od długości próby i okresu weryfikacji. Można jednak zauważyć, że zmienna  $X4\_24$ , a więc opisująca przewidywane zatrudnienie w dziale produkcji mebli, pojawia się w czołówkach wszystkich rankingów. Również zmienna  $X4\_2$  – przewidywane zatrudnienie w grupie przedsiębiorstw zatrudniających 10-49 osób – jest w czterech zestawieniach, przy czym w dwóch na pierwszych miejscach. Należy również zwrócić uwagę, iż bardzo rzadko w modelach występuje część autoregresyjna. W zasadzie pojawia się ona jedynie w ostatniej grupie modeli estymowanych na próbie liczącej 108 obserwacji.

Tabela 2

Błędy RMSE w zależności od długości próby dla dynamiki nominalnych wynagrodzeń w GN dla  $h = 24$  miesiące

$n$	48	60	72	84	96
$s$	81	69	57	45	33
Naiwne	3,90	4,23	4,10	3,81	3,78
AR(1)	5,17	5,19	4,85	3,04	2,14
LI	X6_5 3,24	X6_6 3,31	X6_7 2,95	X6_7 1,53	Y, X6_9 1,42
	X7_12 3,26	X7_4 3,32	X6_6 2,97	X3_5 1,57	Y, X3_29 1,53
	X7_4 3,28	X4_27 3,37	X4_27 3,05	X7_4 1,60	X5_25 1,54
	X4_19 3,32	X6_1 3,41	X3_27 3,06	X3_29 1,60	Y, X3_25 1,55
	X1_3 3,35	X4_19 3,41	X4_8 3,07	X6_9 1,64	Y, X2_25 1,55
	X6_12 3,37	X6_11 3,56	X7_4 3,10	X1_27 1,65	Y, X5_6 1,56
	X6_2 3,43	X4_8 3,19	X6_11 3,10	X6_6 1,65	X7_4 1,56
	X6_1 3,44	X7_12 3,60	X1_29 3,12	X2_9 1,68	X5_28 1,57
	X6_8 3,47	X2_9 3,60	X3_23 3,13	X1_24 1,70	Y, X3_5 1,58
	Y, X3_6 3,48	X5_10 3,61	X1_7 3,13	X5_25 1,71	Y, X2_29 1,58

Te same wyniki dla 24-miesięcznego horyzontu prognozy zestawiono w tab. 2. Z uwagi na dłuższy horyzont nie rozpatrywano tutaj modeli szacowanych na podstawie 108 obserwacji. Wyraźna przewaga zdolności prognostycznych modeli wskaźników wiodących także w tym przypadku została potwierdzona, przy czym różnice są nawet większe. Przykładowo dla modeli estymowanych na podstawie 84 obserwacji RMSE dla najlepszego wskaźnika wyprzedzającego stanowi tylko połowę RMSE modelu autoregresyjnego. W porównaniu do horyzontu 12-miesięcznego wyraźnie lepszymi zdolnościami prognostycznymi cechują się modele korzystające z miar inflacji jako wskaźników wyprzedzających. Prowadzą one we wszystkich pięciu rankingach. Podobnie jak w poprzednim przypadku, także i tutaj widoczna jest niestabilność rankingów. W efekcie trudno wyróżnić zmienną, która dominowałaby niezależnie od liczby obserwacji oraz okresu weryfikacji.

W tab. 3 przedstawiono wyniki procedury wyboru najlepszego modelu niezależnie od długości próby estymacyjnej, zgodnie z procedurą opisaną w poprzedniej części pracy. Jako okres weryfikacji brano pod uwagę 93 ostatnie miesiące.

Dla tego okresu dla wszystkich zmiennych i wszystkich długości prób oszacowano wartości błędów RMSE oraz odchyłeń standardowych tych ocen. Do budowy rankingu brano pod uwagę błąd RMSE powiększony o trzy odchylenia standardowe. W poniższej tab. zestawiono 10 najlepszych modeli wskaźników wiodących oraz najlepszy model autoregresyjny. Dodatkowo podano wartości współczynników determinacji równań regresji (3) służących ocenie błędów prognoz w brakujących okresach.

Tabela 3

Najlepsze modele prognostyczne dla dynamiki nominalnych wynagrodzeń w GN  
dla  $h = 12$  miesięcy

Model	n	RMSE	$\sigma(\text{RMSE})$	R <sup>2</sup>
Naiwny	–	2,72	–	–
AR(1)	96	2,97	0,09	0,977
LI X4_2	108	1,79	0,05	0,995
LI X1_16	108	1,83	0,05	0,998
LI X4_2	96	1,83	0,05	0,972
LI X4_30	96	1,85	0,04	0,971
LI Y, X4_2	108	1,84	0,05	0,996
LI X1_16	96	1,89	0,04	0,979
LI X4_1	96	1,92	0,04	0,984
LI X4_15	96	1,96	0,03	0,982
LI X1_3	108	1,88	0,06	0,999
LI X4_27	96	1,94	0,05	0,983

Z tab. tej wynika, że najlepszymi własnościami prognostycznymi cechuje się model ze zmienną X4\_2 – przewidywanym zatrudnieniem w grupie średnich przedsiębiorstw – jako wskaźnikiem wyprzedzającym szacowanym na podstawie 108 obserwacji. Prognozowana wartość RMSE wynosi 1,79 p.p. przy odchyleniu standardowym tej oceny równym 0,05 p.p. Zmienna ta cechuje się bardzo dobrymi własnościami prognostycznymi, także w przypadku próby 96-elementowej jak również uzupełniona o część autoregresyjną. W prezentowanym zestawieniu znajdują się jedynie zmienne opisujące wyniki badań ankietowych koniunktury. Najlepszy z modeli AR(1) – szacowany na podstawie 96 obserwacji – charakteryzuje się wartością RMSE równą około 3 p.p., a więc wyższą nawet niż model naiwny. Należy również zauważyć, że w czołówce rankingu znajdują się jedynie modele szacowane na długich próbach. Istotny jest również fakt, iż współczynniki determinacji w modelach, na podstawie których szacowano wartości błędów prognoz, we wszystkich przypadkach są bardzo wysokie i przekraczają wartości 0,97.

Tabela 4 zawiera zbiorcze wyniki zdolności prognostycznych dla horyzontu równego 24 miesiące. O ile z tab. 2 wynika, że dla dłuższego horyzontu we wszystkich grupach dominującą rolę odgrywały zmienne reprezentujące wskaźniki inflacji, o tyle w rankingu wyników uśrednionych dla całego okresu weryfikacji znajduje się zaledwie jedna zmienna z tej grupy – X6\_13. W prezentowanym rankingu znajdują się głównie zmienne opisujące wyniki badania koniunktury – najczęściej rezultaty pytania o przyszłe zatrudnienie. Wysoką pozycję zajmuje również zmienna X7\_4 – oczekiwania inflacyjne osób prywatnych. Podobnie jak w przypadku krótszego horyzontu, także tutaj najlepsze wyniki uzyskiwały modele szacowane na próbach długich. Należy zwrócić uwagę, iż w omawianym rankingu częściej pojawiają się modele z częścią autoregresyjną.

Tabela 4

Najlepsze modele prognostyczne dla dynamiki nominalnych wynagrodzeń w GN  
dla  $h = 24$  miesięcy

Model	$n$	RMSE	$\sigma(\text{RMSE})$
Naiwny	–	3,90	–
AR(1)	96	2,85	0,18
LI X1_15	96	2,10	0,11
LI X4_30	84	2,37	0,05
LI X6_13	96	2,19	0,14
LI Y, X5_28	84	2,42	0,07
LI Y, X5_30	84	2,48	0,06
LI X7_4	84	2,42	0,09
LI Y, X5_5	84	2,50	0,08
LI Y, X4_28	96	2,59	0,05
LI Y, X5_29	84	2,52	0,08
LI X4_33	96	2,55	0,09

Podobne analizy przeprowadzono dla wszystkich prognozowanych zmiennych. Poniżej przedstawiono zbiorcze wyniki oceny zdolności prognostycznych modeli. W tab. 5 są zawarte rezultaty prognozowania dynamiki realnych wynagrodzeń w gospodarce narodowej. Widać, że wielkości błędów RMSE są zbliżone do wartości dla dynamiki wynagrodzeń nominalnych, przy czym różnice między zdolnościami prognostycznymi modeli wskaźników wyprzedzających oraz modeli naiwnych i AR(1) są nieco mniejsze niż w przypadku wynagrodzeń nominalnych, szczególnie w odniesieniu do horyzontu 24 miesięcy. W rankingu modeli wskaźników wiodących dominującą rolę odgrywają przewidywania poziomu zatrudnienia. Podobnie jak w poprzednich przypadkach, najlepsze wyniki uzyskiwano dla modeli o najdłuższych próbach estymacyjnych.

Tabela 5

Najlepsze modele prognostyczne dla dynamiki realnych wynagrodzeń w GN

$h = 12$				$h = 24$			
Model	$n$	RMSE	$\sigma(\text{RMSE})$	Model	$n$	RMSE	$\sigma(\text{RMSE})$
Naiwny		2,63		Naiwny		3,57	
AR(1)	60	2,74	0,003	AR(1)	84	3,04	0,10
LI X3_32	108	1,91	0,06	LI Y, X4_24	84	2,56	0,04
LI Y, X3_32	108	1,88	0,07	LI Y, X1_29	84	2,47	0,07
LI X3_32	96	1,96	0,06	LI Y, X4_15	96	2,65	0,04
LI X4_27	108	2,03	0,05	LI Y, X4_7	96	2,53	0,12
LI Y, X4_27	108	2,03	0,05	LI X5_22	96	2,62	0,10
LI X4_24	108	2,02	0,07	LI Y, X4_28	96	2,81	0,04
LI X4_22	108	2,11	0,04	LI X7_2	96	2,64	0,10
LI X6_7	108	1,97	0,09	LI Y, X3_25	96	2,62	0,11
LI Y, X4_24	108	2,03	0,07	LI Y, X4_32	84	2,78	0,06
LI X4_27	96	2,11	0,05	LI X5_10	72	2,86	0,03

W tab. 6-7 zawarto wyniki analiz dla dynamiki nominalnych oraz realnych wynagrodzeń w sektorze przedsiębiorstw. Wartości RMSE są nieco wyższe niż w przypadku wynagrodzeń w gospodarce narodowej, co odzwierciedla fakt większej zmienności tej zmiennej. Nie ma natomiast większej różnicy pomiędzy zdolnościami prognostycznymi modeli w odniesieniu do miar nominalnych i realnych. We wszystkich przypadkach modele wskaźników wiodących wypadają wyraźnie lepiej od modeli naiwnych i autoregresyjnych. W odniesieniu do dynamiki wynagrodzeń nominalnych najlepszymi wskaźnikami wiodącymi są przewidywania odnośnie do poziomu zatrudnienia oraz przewidywania ogólnej sytuacji gospodarczej. W przypadku wynagrodzeń realnych wszystkie czołowe miejsca rankingu zajmują wyniki badania koniunktury, przy czym każda z grup ma kilku swoich reprezentantów. Dodatkowo wiele modeli z czołówki rankingów posiada składnik autoregresyjny. Na koniec warto zwrócić uwagę, iż w prawie wszystkich rankingach wskaźników wyprzedzających w czołówkach znajdują się rezultaty badań ankietowych w sektorze nietrwałych (27) i trwałych dóbr konsumpcyjnych (28).

Tabela 6

Najlepsze modele prognostyczne dla dynamiki nominalnych wynagrodzeń w sektorze przedsiębiorstw

$h = 12$				$h = 24$			
Model	$n$	RMSE	$\sigma(\text{RMSE})$	Model	$n$	RMSE	$\sigma(\text{RMSE})$
Naiwny		3,80		Naiwny		5,15	
AR(1)	84	3,37	0,01	AR(1)	72	3,70	
LI X4_2	108	2,53	0,08	LI Y, X1_25	96	2,44	0,21
LI X4_27	96	2,58	0,07	LI X4_27	96	2,76	0,12
LI X4_2	96	2,61	0,06	LI Y, X4_22	96	2,94	0,14
LI Y, X1_28	96	2,61	0,06	LI X4_27	84	3,10	0,11
LI Y, X7_3	96	2,57	0,09	LI X4_4	96	3,26	0,06
LI Y, X1_2	108	2,51	0,11	LI Y, X2_14	96	2,75	0,25
LI Y, X1_22	96	2,62	0,09	LI Y, X6_11	96	2,85	0,22
LI Y, X1_5	96	2,72	0,05	LI Y, X6_7	96	3,10	0,13
LI Y, X1_28	108	2,59	0,12	LI X4_24	96	2,94	0,20
LI Y, X1_2	96	2,64	0,10	LI Y, X5_5	96	2,80	0,25

Tabela 7

Najlepsze modele prognostyczne dla dynamiki realnych wynagrodzeń w sektorze przedsiębiorstw

$h = 12$				$h = 24$			
Model	$n$	RMSE	$\sigma(\text{RMSE})$	Model	$n$	RMSE	$\sigma(\text{RMSE})$
Naiwny		3,86		Naiwny		4,92	
AR(1)	96	3,19	0,05	AR(1)	72	3,76	0,02
LI X3_32	108	2,53	0,10	LI Y, X1_1	96	2,51	0,06
LI Y, X4_32	108	2,56	0,11	LI Y, X3_1	96	2,64	0,06
LI X4_27	108	2,71	0,08	LI Y, X2_30	96	2,89	0,10
LI Y, X1_29	108	2,63	0,11	LI Y, X2_28	96	2,98	0,07
LI X1_5	108	2,64	0,11	LI Y, X5_10	96	2,93	0,15
LI X3_18	108	2,66	0,12	LI X1_16	96	3,01	0,13
LI X4_27	96	2,75	0,09	LI Y, X2_5	84	3,19	0,09
LI X2_27	72	3,02	0,01	LI X1_1	96	2,91	0,19
LI X1_5	96	2,75	0,11	LI Y, X3_18	96	3,24	0,12
LI Y, X2_32	108	2,85	0,08	LI Y, X4_16	84	3,39	0,07



## Podsumowanie

W pracy analizowano zdolności prognostyczne modeli wskaźników wyprzedzających w odniesieniu do dynamiki wynagrodzeń w Polsce w latach 2000-2012. Wśród potencjalnych wskaźników wyprzedzających brano pod uwagę przede wszystkim wyniki ankietowego badania koniunktury w przedsiębiorstwach przemysłowych oraz wskaźniki inflacji. Ważnym punktem analiz była również zaproponowana przez autora nowa metoda porównywania zdolności prognostycznych modeli, których parametry były szacowane na próbach o różnej liczbie obserwacji, opartych na analizie dokładności prognoz wygasłych. Istota tego podejścia była oparta na prognozowaniu błędów prognoz.

Z przeprowadzonych badań wypływają następujące wnioski. Po pierwsze, modele wskaźników wiodących cechują się wyraźnie lepszymi zdolnościami prognostycznymi w stosunku do modeli naiwnych oraz autoregresyjnych w odniesieniu do wszystkich zmiennych oraz horyzontów. Po drugie, nie stwierdzono wyraźnych różnic w wielkości błędów prognoz przy prognozowaniu wynagrodzeń w gospodarce narodowej oraz w sektorze przedsiębiorstw, a także pomiędzy wartościami nominalnymi i realnymi wynagrodzeń. Wśród rozważanych wskaźników wiodących najczęściej najniższymi błędami RMSE cechowały się zmienne dotyczące przewidywań poziomu zatrudnienia oraz ogólnej sytuacji gospodarczej, szczególnie wśród przedsiębiorstw wytwarzających trwałe i nietrwałe dobra konsumpcyjne. Zarówno wskaźniki inflacji, jak i inne pojedyncze zmienne rzadko pojawiały się w czołówkach rankingów zdolności prognostycznych. Ponadto zdolności prognostyczne poszczególnych modeli wahają się w zależności od długości próby estymacyjnej oraz okresu weryfikacji, dlatego trudno jest wskazać zmienną dominującą niezależnie od tych czynników. Stosując podejście zaproponowane w pracy, pokazano, iż najlepszymi zdolnościami prognostycznymi cechują się zwykle modele estymowane na próbach długich, co może świadczyć o stabilności relacji pomiędzy zmiennymi prognozowanymi a wskaźnikami wyprzedzającymi w analizowanej próbie.

## Literatura

- Białowolski P., Żochowski D.: 2006, *Wskaźniki wyprzedzające*. Oficyna Wydawnicza SGH, Warszawa.
- Cieślak M., red., 2001: *Prognozowanie gospodarcze. Metody i zastosowania*. Wydawnictwo Naukowe PWN, Warszawa.
- Dittmann P., 2003: *Prognozowanie w przedsiębiorstwie*. Oficyna Ekonomiczna, Kraków.

- Giacomini R., White H., 2006: *Tests of Conditional Predictive Ability*. „Econometrica” Vol. 74(6).
- Szabela-Pasierbińska E., 2011: *Prognozy wynagrodzenia nominalnego brutto we Wrocławiu w latach 2008-2013*. Wydawnictwo Uniwersytetu Gdańskiego, Gdańsk.
- Szafrański G., 2011: *Krótkoterminowe prognozy polskiej inflacji w oparciu o wskaźniki wyprzedzające*. „Materiały i Studia” nr 263, Warszawa.
- Todd E.C., McCracken M.W., 2011: *Advances in Forecast Evaluation*. Federal Reserve Bank of Cleveland Working Paper 11-20.
- Zasady metodyczne statystyki rynku pracy i wynagrodzeń*, 2008: GUS, Warszawa.

## SHORT TERM FORECASTING OF WAGE DYNAMICS IN POLAND

### Summary

In the paper a forecasting ability of leading indicator models for wage dynamics in Poland for 12- and 24-month horizon is analyzed. Mean square error of ex post forecasts was used as the accuracy measure. A new method for comparison of the forecast accuracy for models that are estimated on samples of different lengths is presented. It focuses on estimating missing forecast errors for one model. The results show that the leading indicator models provide superior forecasting abilities compared to naïve and autoregressive models for all variables and horizons. Moreover the models estimated on longer samples usually generate more accurate forecasts. Among the investigated variables the expectations regarding future employment level as well as general economic conditions, especially among consumption goods producers, generated the forecasts with the lowest RMSE.

## Załącznik

## Opis zmiennych objaśniających

Grupa	Oznaczenie zmiennej	Nazwa zmiennej
1	2	3
Badania ankietowe koniunktury 1 – przewidywana ogólna sytuacja gospodarcza, 2 – przewidywany portfel zamówień, 3 – przewidywana produkcja, 4 – przewidywane zatrudnienie, 5 – przewidywane ceny sprzedaży wyrobów	Xi_1	Ogółem
	Xi_2	klasa 10-49 pracujących
	Xi_3	klasa 50-249 pracujących
	Xi_4	klasa 250 i więcej pracujących
	Xi_5	Sektor: Produkcja artykułów spożywczych, napoje, wyroby tytoniowe
	Xi_6	Sektor: Produkcja wyrobów tekstylnych
	Xi_7	Sektor: Produkcja odzieży
	Xi_8	Sektor: Produkcja skór i wyrobów ze skór wyprawionych
	Xi_9	Sektor: Produkcja wyrobów z drewna oraz korka, z wyłączeniem mebli; produkcja wyrobów ze słomy i materiałów używanych do wyplatania
	Xi_10	Sektor: Produkcja papieru i wyrobów z papieru
	Xi_11	Sektor: Poligrafia i reprodukcja zapisanych nośników informacji
	Xi_12	Sektor: Wytwarzanie i przetwarzanie koksu i produktów rafinacji ropy naftowej
	Xi_13	Sektor: Produkcja chemikaliów i wyrobów chemicznych
	Xi_14	Sektor: Produkcja podstawowych substancji farmaceutycznych oraz leków i pozostałych wyrobów farmaceutycznych
	Xi_15	Sektor: Produkcja wyrobów z gumy i tworzyw sztucznych
	Xi_16	Sektor: Produkcja wyrobów z pozostałych mineralnych surowców niemetalicznych
	Xi_17	Sektor: Produkcja metali
	Xi_18	Sektor: Produkcja metalowych wyrobów gotowych, z wyłączeniem maszyn i urządzeń
	Xi_19	Sektor: Produkcja komputerów, wyrobów elektronicznych i optycznych
	Xi_20	Sektor: Produkcja urządzeń elektrycznych
	Xi_21	Sektor: Produkcja maszyn i urządzeń, gdzie indziej niesklasyfikowana

1	2	3
	Xi_22	Sektor: Produkcja pojazdów samochodowych, przyczep i naczep, z wyłączeniem motocykli
	Xi_23	Sektor: Produkcja pozostałego sprzętu transportowego
	Xi_24	Sektor: Produkcja mebli
	Xi_25	Sektor: Pozostała produkcja wyrobów
	Xi_26	Sektor: Naprawa, konserwacja i instalowanie maszyn i urządzeń
	Xi_27	Sektor: Trwałe dobra konsumpcyjne
	Xi_28	Sektor: Nietrwałe dobra konsumpcyjne
	Xi_29	Sektor: Żywność i napoje
	Xi_30	Sektor: Dobra konsumpcyjne
	Xi_31	Sektor: Energia
	Xi_32	Sektor: Dobra pośrednie
	Xi_33	Sektor: Dobra inwestycyjne
	6 – Wskaźniki inflacji HICP	X6_1
X6_2		Żywność i napoje bezalkoholowe
X6_3		Napoje alkoholowe i wyroby tytoniowe
X6_4		Odzież i obuwie
X6_5		Utrzymanie mieszkania
X6_6		Meble oraz artykuły wyposażenia domowego
X6_7		Zdrowie
X6_8		Transport
X6_9		Komunikacja
X6_10		Rekreacja i kultura
X6_11		Edukacja
X6_12		Restauracje i hotele
X6_13		Inne dobra i usługi
7 – Pozostałe zmienne	X7_1	Przeciętne zatrudnienie w sektorze przedsiębiorstw
	X7_2	Wskaźnik cen produkcji sprzedanej przemysłu
	X7_3	WIG20
	X7_4	Oczekiwania inflacyjne
	X7_5	M3
	X7_6	WIBOR3m
	X7_7	Stopa bezrobocia rejestrowanego
	X7_8	Produkcja przemysłowa
	X7_9	PMI
	X7_10	IFO Germany Business Climate
	X7_11	IFO Germany Business Situation
	X7_12	IFO Germany Business Expectations