

Jacek Welc

Uniwersytet Ekonomiczny we Wrocławiu
WNP Ekspert Sp. z o.o.

KWARTALNE WYNIKI FINANSOWE SPÓŁEK GIEŁDOWYCH – ŁĄCZENIE PROGNOZ ANALITYKÓW Z PROGNOZAMI MECHANICZNYMI A DOKŁADNOŚĆ PROGNOZ

Streszczenie: Prognozy wyników finansowych spółek stanowią nieodłączny element modeli wyceny. Przy sporządzaniu prognoz analitycy wykorzystują szeroki zakres informacji. Jednak badania trafności prognoz nie są jednoznaczne. Niektóre wskazują na przewagę (w zakresie dokładności) prognoz analityków w porównaniu z prognozami mechanicznymi, natomiast wyniki innych wskazują na większą dokładność prostych (często naiwnych) metod niż prognoz analityków. Sugeruje to możliwość redukcji błędów poprzez łączenie prognoz. W artykule zbadano wpływ łączenia prognoz analityków z predykcjami autoregresyjnymi na dokładność predykcji zysków operacyjnych spółek. Badanie wykazało, iż proste łączenie prognoz (poprzez liczenie średniej z dwóch prognoz) nie powoduje obniżenia mediany względnych błędów, jednak przyczynia się do redukcji średniego arytmetycznego błędu bezwzględnego.

Słowa kluczowe: prognozowanie wyników finansowych, dokładność prognoz, łączenie prognoz.

1. Wstęp

Prognozy wyników finansowych spółek stanowią nieodłączny element większości modeli ich wyceny. Przekroczenie lub niewykonanie przez spółki prognoz finansowych stanowi często także istotne kryterium oceny jakości zarządzania oraz perspektyw rozwojowych tych spółek. Przy sporządzaniu prognoz wyników finansowych analitycy wykorzystują zazwyczaj szeroki zakres dostępnych informacji dotyczących zarówno analizowanej spółki (np. planowanych działań marketingowych, zmian struktury sprzedaży, wielkości zatrudnienia, planowanych inwestycji itd.), jak i jej otoczenia ekonomicznego (np. przewidywanej koniunktury gospodarczej, zachowań konkurentów, preferencji nabywców, zmian kursów walutowych itd.). Jednak jakość prognoz wyników finansowych sporządzanych przez analityków giełdowych wzbudza wiele kontrowersji, a badania relatywnej trafności tych prognoz nie są jednoznaczne. Niektóre badania przeprowadzone na danych dotyczących spółek

notowanych na giełdach amerykańskich wskazują na przewagę (w zakresie dokładności) prognoz analityków w porównaniu z prognozami mechanicznymi (uzyskanymi z prostych modeli szeregów czasowych) [White, Sondhi, Fried 2003, s. 720-721; Brown 1996, s. 40; Chatfield, Moyer, Sisneros 1989], natomiast wyniki innych badań wskazują na wyższą dokładność prostych (często nawet naiwnych) metod prognozytycznych nad prognozami analityków giełdowych [Dreman 1998, s. 89-136; Malkiel 2007, s. 153]. Inne badania wskazują na przewagę analityków nad prognozami mechanicznymi w przypadku prognoz z horyzontem jedno- oraz dwukwartalnym, zbliżoną dokładność w przypadku prognoz z horyzontem trzykwartalnym oraz przewagę prognoz mechanicznych nad prognozami analityków w przypadku prognoz o horyzontach dłuższych niż trzy kwartały [O'Brien 1988; Rothovius 2008]. Jeszcze inne badania wskazują, iż w odniesieniu do spółek notujących straty prognozy analityków okazują się często mniej dokładne nawet od prognoz naiwnych [Ciccone 2002]. Oznacza to, iż w okresach pogarszających się (poprawiających się) wyników finansowych spółek, kiedy rośnie udział spółek ponoszących straty, relatywna jakość prognoz mechanicznych rośnie (obniża się). Natomiast badania przeprowadzone dla spółek notowanych na warszawskiej Giełdzie Papierów Wartościowych wskazują, iż w ich przypadku prognozy analityków dotyczące kwartalnych wyników finansowych charakteryzują się znacznie wyższą dokładnością (mierzoną medianą błędów bezwzględnych) niż prognozy alternatywne otrzymane z modeli autoregresyjnych [Welc 2009].

Niezależnie od relatywnej dokładności prognoz analityków i prognoz mechanicznych (w tym autoregresyjnych) badania empiryczne ogólnie wskazują na dużą niedokładność predykcji wyników finansowych spółek. Wynika to w znacznej mierze z dużej zmienności tych wyników finansowych oraz dużego udziału czynników o charakterze dyskrecjonalnym i nieprzewidywalnych (dokonywanych odpisów, zaciąganych rezerw, aktualizacji wartości aktywów itd.) w raportowanych wynikach finansowych. W związku z tym w literaturze wskazuje się na potencjalnie wysoką skuteczność łączenia prognoz w redukcji średnich błędów predykcji [Bunn 1988; Terregrossa 1999; Guerard, Beidleman 1987; Harris, Conroy 1987]. Niektóre badania wskazują na możliwość istotnego zmniejszenia błędów prognoz nawet w sytuacjach, gdy pojedyncze prognozy charakteryzują się relatywnie niską dokładnością [Lobo, Nair 2007]. Pomimo jednak wielu badań wskazujących na pozytywny wpływ łączenia prognoz wyników finansowych na średni błąd predykcji w literaturze nie wskazuje się jednoznacznie zalecanej procedury łączenia prognoz, w szczególności w zakresie doboru indywidualnych prognoz tworzących prognozy łączone oraz w zakresie doboru wag przypisywanych poszczególnym prognozom indywidualnym. Niektóre badania wskazują na większą dokładność prognoz łączonych, gdy nie narzuca się wagom, by sumowały się do jedności [Holmen 1987], natomiast inne badania wskazują na przewagę najprostszych metod łączenia prognoz (w tym prostych średnich arytmetycznych) nad procedurami pozwalającymi szacować optymalne systemy wag [Timmermann 2005].

Celem artykułu jest zbadanie wpływu łączenia prognoz sporządzanych przez analityków giełdowych z predykcjami otrzymanymi z kilku alternatywnych modeli autoregresyjnych na dokładność predykcji kwartalnych zysków operacyjnych polskich spółek giełdowych. Zgodnie z przyjętą hipotezą badawczą łączenie prognoz przyczynia się do redukcji błędów prognoz indywidualnych. Mimo że w przypadku kwartalnych wyników finansowych polskich spółek prognozy analityków charakteryzują się znacznie niższą medianą błędów niż prognozy z pojedynczych modeli autoregresyjnych, łączenie prognoz analityków z predykcjami autoregresyjnymi może się przyczynić do redukcji średnich błędów (szczególnie, gdy błędy prognoz analityków i prognoz mechanicznych są słabo lub ujemnie skorelowane). W badaniu wykorzystano dwa podejścia do budowy prognoz łączonych: podejście oparte na analizie korelacji względnych błędów poszczególnych prognoz i podejście oparte na analizie regresji rzeczywistych wyników finansowych względem prognoz tych wyników otrzymanych przy wykorzystaniu różnych podejść prognostycznych.

2. Zastosowana metodologia badawcza

Analiza porównawcza przeprowadzona została dla kwartalnych prognoz (z jednokwartalnym horyzontem prognostycznym) zysku operacyjnego opublikowanych przez cztery domy maklerskie w okresie od początku 2005 r. do końca 2008 r. Obejmująca ten okres pierwotna próba objęła ponad 1000 prognoz zysku operacyjnego sporządzonych dla kilkudziesięciu notowanych na giełdzie warszawskiej spółek. Ze względu jednak na ograniczoną dostępność danych i konieczność oszacowania modeli autoregresyjnych ostateczna próba, na podstawie której dokonano analizy porównawczej, objęła 648 prognoz zysku operacyjnego (uwzględniono wszystkie prognozy, dla których możliwe było uzyskanie prognoz alternatywnych wygenerowanych przez wszystkie analizowane modele autoregresyjne).

Liczbę uwzględnionych w badaniu prognoz dla poszczególnych kwartałów lat 2005-2008 przedstawia tab. 1. Obserwacja danych wskazuje, iż żaden spośród uwzględnionych w analizie kwartałów nie zdominował wyników badania (liczba prognoz dla każdego z kwartałów nie przekracza 15,0% ogólnej liczby uwzględnionych w badaniu prognoz). Udział prognoz dla poszczególnych spółek w ogólnej liczbie uwzględnionych w badaniu prognoz przedstawia tab. 2. Obserwacja danych wskazuje, iż żadna ze spółek nie zdominowała wyników badania (udział prognoz dla każdej ze spółek w ogólnej liczbie prognoz uwzględnionych w badaniu nie przekracza 5,0%).

Jako benchmarki dla prognoz analityków wykorzystano następujące modele autoregresyjne:

- Model 1 – autoregresja pierwszego rzędu z addytywną sezonowością, oszacowana w oparciu na próbie obejmującej ostatnie 16 kwartałów.
- Model 2 – autoregresja pierwszego rzędu z addytywną sezonowością, oszacowana w oparciu na próbie obejmującej ostatnie 12 kwartałów.

- Model 3 – autoregresja czwartego rzędu bez sezonowości, oszacowana w oparciu na próbie obejmującej ostatnie 12 kwartałów.
- Model 4 – autoregresja czwartego rzędu z addytywną sezonowością, oszacowana w oparciu na próbie obejmującej ostatnie 12 kwartałów.
- Model 5 – autoregresja pierwszego rzędu z addytywną sezonowością oraz trzema zmiennymi zero-jedynkowymi dla obserwacji nietypowych, oszacowana w oparciu na próbie obejmującej ostatnie 16 kwartałów.
- Model 6 – autoregresja pierwszego rzędu z addytywną sezonowością, trzema zmiennymi zero-jedynkowymi dla obserwacji nietypowych oraz zmienną zero-jedynkową dla pojedynczej zmiany strukturalnej, oszacowana w oparciu na próbie obejmującej ostatnie 16 kwartałów.

Tabela 1. Liczba uwzględnionych w badaniu prognoz zysku operacyjnego dla poszczególnych kwartałów lat 2005-2008

Okres	Liczba prognoz	Udział w ogólnej liczbie prognoz (w %)
I kwartał 2005	23	3,5
II kwartał 2005	31	4,8
III kwartał 2005	30	4,6
IV kwartał 2005	71	11,0
I kwartał 2006	57	8,8
II kwartał 2006	63	9,7
III kwartał 2006	35	5,4
IV kwartał 2006	63	9,7
I kwartał 2007	46	7,1
II kwartał 2007	45	6,9
III kwartał 2007	45	6,9
IV kwartał 2007	21	3,2
I kwartał 2008	22	3,4
II kwartał 2008	21	3,2
III kwartał 2008	39	6,0
IV kwartał 2008	36	5,6
Razem	648	100,0

Źródło: Dom Inwestycyjny BRE Banku, Dom Maklerski Millennium, Bankowy Dom Maklerski PKO, Dom Maklerski BZ WBK; opracowanie własne.

Tabela 2. Udział prognoz dla poszczególnych spółek w ogólnej liczbie prognoz uwzględnionych w badaniu

Spółka	Udział w ogólnej liczbie badanych prognoz (w %)
PKN Orlen SA	4,9
Agora SA	4,6
Asseco Poland SA	4,6
KGHM SA	4,3
Netia SA	4,3
Comarch SA	3,8
Prokom SA	3,8
Telekomunikacja Polska SA	3,8
Modni Świecie SA	3,4
Sygnity SA	3,2
Polimex Mostostal-Siedlce SA	3,0
Kęty S.A.	2,9
Farmacol SA	2,6
PGF SA	2,6
Kogeneracja SA	2,1
ABG Ster-Projekt SA	2,0
Budimex SA	2,0
Pozostałe (58 spółek)	42,2
Razem	100,0

Źródło: Dom Inwestycyjny BRE Banku, Dom Maklerski Millennium, Bankowy Dom Maklerski PKO, Dom Maklerski BZ WBK; opracowanie własne.

W modelach z addytywną sezonowością jako zmienne sezonowe wykorzystano trzy zmienne zero-jedynkowe przyjmujące wartość 1 w przypadku danego kwartału oraz wartość 0 – w przypadku pozostałych kwartałów.

W modelach 5 oraz 6 jako zmienne zero-jedynkowe dla obserwacji nietypowych wykorzystano zmienne przyjmujące wartość 1 dla danej obserwacji nietypowej oraz wartość 0 dla pozostałych obserwacji. W celu identyfikacji obserwacji nietypowych wykorzystano sekwencyjny test na obserwację nietypową. Test ten polega na wprowadzeniu do analizowanej regresji zero-jedynkowej zmiennej objaśniającej o postaci $D_i = 0_1, \dots, 0_{i-1}, 1_i, \dots, 1_T$, gdzie T oznacza rozmiar próby. W kolejnych sekwencjach dokonuje się reestymacji modelu, zmieniając wartość i , od $i = 1$ do $i = T$. Idea metody opiera się na obserwacji, dla którego okresu zmienna D jest najbardziej istotna statystycznie. Istotna statystycznie i najwyższa wartość statystyki istotności w tym okresie oznacza, iż okres ten stanowi obserwację nietypową. W sekwencyjnym teście na obserwację nietypową jako miarę istotności wykorzystano test t -Studenta. W szacowanych modelach autoregresyjnych uwzględniono nie więcej niż trzy zmienne zero-jedynkowe dla obserwacji nietypowych.

W modelu 6 jako zmienną zero-jedynkową dla pojedynczej zmiany strukturalnej wykorzystano zmienną przyjmującą wartość 0 dla wszystkich obserwacji przed zidentyfikowaną zmianą strukturalną oraz wartość 1 dla wszystkich obserwacji w okresie od zmiany strukturalnej. W celu identyfikacji miejsca wystąpienia zmiany strukturalnej wykorzystano sekwencyjny test na zmianę strukturalną. Test ten polega na wprowadzeniu do analizowanej regresji zero-jedynkowej zmiennej objaśniającej o postaci $D_i = 0_1, \dots, 0_{i-1}, 1_i, \dots, 1_T$, gdzie T oznacza rozmiar próby, natomiast i oznacza potencjalne miejsce wystąpienia zmiany strukturalnej. W kolejnych sekwencjach dokonuje się reestymacji modelu, zmieniając wartość i , od $i = 1$ do $i = T - 1$. Idea metody opiera się na obserwacji, dla którego okresu zmienna D jest najbardziej istotna statystycznie. Istotna statystycznie i najwyższa wartość statystyki istotności w tym okresie oznacza, iż miała w nim miejsce zmiana struktury analizowanej zależności [Barassi, Caporale, Hall 2001, s. 9-10]. W sekwencyjnym teście na zmianę strukturalną jako miarę istotności wykorzystano test t -Studenta. Wszystkie modele autoregresyjne szacowano przy wykorzystaniu klasycznej metody najmniejszych kwadratów.

Dla wszystkich prognoz objętych badaniem (tzn. dla prognoz analityków oraz prognoz wygenerowanych przez sześć analizowanych modeli autoregresyjnych) obliczono błędy prognozy według następującej formuły:

$$B = \left(\frac{P_t - W_t}{W_t} - 1 \right) \times 100, \quad (1)$$

gdzie: B – procentowy błąd prognozy; P_t – prognozowana wartość zmiennej w okresie t ; W_t – rzeczywista wartość prognozowanej zmiennej w okresie t .

Dla prognoz analityków i dla predykcji otrzymanych z każdego modelu obliczono błędy przeciętne prognoz kwartalnych zysków operacyjnych. Obliczono średnie arytmetyczne i mediany błędów względnych oraz bezwzględnych. Następnie sporządzono prognozy łączone (łączące prognozy analityków i prognozy mechaniczne), posługując się dwiema alternatywnymi procedurami. W pierwszej z nich wykorzystano współczynniki korelacji błędów względnych predykcji, kierując się założeniem, iż niska lub ujemna korelacja błędów względnych prognoz może się przyczynić do wzajemnego „znoszenia się” tych błędów. W oparciu na obliczonych współczynnikach korelacji błędów dokonano wyboru modeli autoregresyjnych, których względne błędy predykcji są słabo (lub ujemnie) skorelowane z względnymi błędami prognoz analityków, a następnie sporządzono prognozy łączone składające się z prognoz analityków oraz predykcji mechanicznych otrzymanych z modeli o niskich korelacjach błędów prognoz. W podejściu tym prognozy łączone uzyskano jako średnie arytmetyczne dwóch prognoz indywidualnych (zakładano zatem równe i sumujące się do jedności wagi prognoz indywidualnych).


W drugim podejściu dokonano oszacowania regresji liniowej, w której zmienną objaśnianą stanowiły rzeczywiste zyski operacyjne spółek, natomiast potencjalne

zmienne objaśniające stanowiły prognozy tych zysków sporządzone przez analityków i otrzymane z sześciu alternatywnych modeli autoregresyjnych. W przypadku tym dokonano selekcji zmiennych objaśniających przy wykorzystaniu procedury modelowania „od ogółu do szczegółu”, kolejno redukując zmienne nieistotne statystycznie (przy wykorzystaniu testu *t*-Studenta na poziomie istotności 0,05). Procedura ta umożliwia automatyczną i obiektywną selekcję indywidualnych prognoz tworzących prognozy łączone przy jednoczesnym automatycznym przypisaniu wag poszczególnym prognozom indywidualnym (wagi te stanowią w tym przypadku parametry strukturalne szacowanej regresji). W podejściu tym prognozy łączone stanowią wartości teoretyczne kwartalnych zysków operacyjnych otrzymane z oszacowanej regresji.

Dla wszystkich analizowanych wariantów prognoz łączonych obliczono i porównano średnie arytmetyczne i mediany bezwzględnych błędów prognoz.

3. Otrzymane rezultaty

Wykres na rys. 1 przedstawia miary przeciętne (medianę i średnią arytmetyczną) bezwzględnych błędów prognoz kwartalnego zysku operacyjnego sporządzonych przez analityków giełdowych (z czterech domów maklerskich) oraz otrzymanych z analizowanych sześciu modeli autoregresyjnych.



* Mediana bezwzględnych błędów prognoz kwartalnego zysku operacyjnego.

** Średnia arytmetyczna bezwzględnych błędów prognoz kwartalnego zysku operacyjnego.

Rys. 1. Przeciętne błędy bezwzględne prognoz kwartalnego zysku operacyjnego


Źródło: Dom Inwestycyjny BRE Banku, Dom Maklerski Millennium, Bankowy Dom Maklerski PKO, Dom Maklerski BZ WBK; opracowanie własne.

Obserwacja wykresu wskazuje na wyraźną przewagę (w zakresie median błędów) prognoz analityków nad analizowanymi prognozami mechanicznymi. Choć mediana błędów prognoz analityków wyniosła aż 23,6%, to jest to poziom błędów znacznie niższy niż w przypadku wszystkich sześciu badanych modeli autoregresyjnych, których mediany błędów bezwzględnych kształtują się w przedziale między 37,2 a 47,7%. Należy jednak zwrócić uwagę, iż modele 5 oraz 6 wykazują średnie (mierzone średnią arytmetyczną) błędy predykcji na poziomach niższych niż w przypadku prognoz analityków (choć mediana błędów prognoz analityków znajduje się na znacznie niższym poziomie). Wydaje się zatem, iż prognozy analityków, choć charakteryzują się generalnie niższymi błędami przeciętnymi (mierzonymi medianą) niż obydwa te modele autoregresyjne, wykazują wyższy udział obserwacji nietypowych (charakteryzujących się błędami znacznie wykraczającymi poza standardowy przedział błędów). Obserwacje te potwierdzają wysoką nieprzewidywalność zysków operacyjnych spółek, w szczególności biorąc pod uwagę to, iż przeprowadzona analiza dotyczy jedynie prognoz o horyzoncie jednokwartalnym. Na uwagę zasługuje fakt, iż zarówno w przypadku prognoz analityków, jak i prognoz wygenerowanych przez wszystkie analizowane modele autoregresyjne średnie arytmetyczne błędów bezwzględnych znacząco przewyższają ich mediany. Wskazuje to na duży wpływ obserwacji nietypowych charakteryzujących się ponadprzeciętnie wysokimi błędami prognoz.

Spśród analizowanych modeli autoregresyjnych najniższą medianą bezwzględnych błędów prognoz zysku operacyjnego charakteryzują się model 2 i model 1, czyli modele prostej autoregresji pierwszego rzędu z addytywną sezonowością. Odmienne wskazania otrzymano w odniesieniu do średnich arytmetycznych błędów bezwzględnych. Zgodnie z tą miarą najniższymi błędami (niższymi niż w przypadku prognoz analityków) prognoz kwartalnego zysku operacyjnego charakteryzowały się model 5 (autoregresja pierwszego rzędu z addytywną sezonowością oraz trzema zmiennymi zero-jedynkowymi dla obserwacji nietypowych) oraz model 6 (autoregresja pierwszego rzędu z addytywną sezonowością, trzema zmiennymi zero-jedynkowymi dla obserwacji nietypowych i zmienną zero-jedynkową dla pojedynczej zmiany strukturalnej).

Rysunek 2 przedstawia współczynniki korelacji między błędami względnymi prognoz analityków i prognoz otrzymanych z analizowanych sześciu modeli autoregresyjnych.


Wszystkie współczynniki korelacji błędów prognoz przyjmują wartości dodatnie istotne statystycznie na poziomie istotności 0,05. Jednak siłę korelacji błędów prognoz analityków i prognoz otrzymanych z sześciu modeli autoregresyjnych należy uznać za umiarkowaną. W związku z tym stworzono sześć wersji łączonych prognoz kwartalnych zysków operacyjnych w ten sposób, iż każda łączona prognoza stanowiła średnią arytmetyczną z prognozy analityków i prognozy otrzymanej z jednego modelu autoregresyjnego. Dla obliczonych w ten sposób prognoz łączonych obliczono średnie arytmetyczne i mediany błędów bezwzględnych predykcji. Miary te przedstawia wykres na rys. 3.



* Współczynniki korelacji obliczono w oparciu na próbie obejmującej 648 obserwacji. Na osi odciętych ujęto pary prognoz, dla których obliczono współczynniki korelacji liniowej. Przyjęto oznaczenie „A” dla prognoz analityków, oznaczenie „M1” – dla prognoz z modelu 1, oznaczenie „M2” – dla prognoz z modelu 2 itd.

Rys. 2. Współczynniki korelacji liniowej między błędami względnymi prognoz analityków i prognoz otrzymanych z badanych sześciu modeli autoregresyjnych*

Źródło: opracowanie własne.



* Pod słupkami na wykresie podano prognozy indywidualne wchodzące w skład prognoz łączonych. Przyjęto oznaczenie „A” dla prognoz analityków, „M1” – dla prognoz z modelu 1, „M2” – dla prognoz z modelu 2 itd.; ** Mediana bezwzględnych błędów prognoz łączonych kwartalnego zysku operacyjnego; *** Średnia arytmetyczna bezwzględnych błędów prognoz łączonych kwartalnego zysku operacyjnego.

Rys. 3. Przeciętne błędy bezwzględne łączonych prognoz kwartalnego zysku operacyjnego*

Źródło: opracowanie własne.

Mediany bezwzględnych błędów prognoz łączonych mieszczą się w przedziale między 28,8 i 32,1%. W każdym przypadku są one zatem znacznie wyższe niż mediana błędów prognoz analityków, która wyniosła 23,6%. Zatem w przypadku kwartalnych zysków operacyjnych polskich spółek giełdowych tworzenie kombinacji (jako średniej arytmetycznej) prognoz analityków oraz prognoz autoregresyjnych nie prowadzi do uzyskania mediany błędów bezwzględnych na poziomie niższym niż w przypadku prognoz analityków. Do odmiennych wniosków prowadzi jednak obserwacja średnich arytmetycznych błędów bezwzględnych. Miara ta wyniosła 102,5% w kombinacji złożonej z prognoz analityków i prognoz z modelu 5 oraz 104,3% – w kombinacji złożonej z prognoz analityków i prognoz z modelu 6. Obie te kombinacje charakteryzują się zatem niższymi średnimi arytmetycznymi błędami prognoz niż predykcje analityków (których średni arytmetyczny błąd wyniósł 118,2%) oraz predykcje indywidualne z modelu 5 i modelu 6 (których średni błąd arytmetyczny wyniósł odpowiednio: 110,3 i 112,8%). Należy przy tym zauważyć, iż nie są to kombinacje stworzone z prognoz otrzymanych z modelu o najniższej korelacji błędów względnych z błędami prognoz analityków. Można jednak stwierdzić, iż w przypadku kwartalnych zysków operacyjnych polskich spółek giełdowych tworzenie kombinacji (jako średniej arytmetycznej) prognoz analityków i prognoz autoregresyjnych przyczynia się do redukcji średnich arytmetycznych bezwzględnych błędów prognoz. Zatem łączenie prognoz analityków z predykcjami autoregresyjnymi, choć nie zwiększa dokładności prognoz mierzonej medianą błędów absolutnych, przyczynia się do nieznacznego zmniejszenia wpływu obserwacji nietypowych (charakteryzujących się ponadprzeciętnie wysokimi błędami) na dokładność predykcji.

Alternatywnym podejściem zastosowanym do tworzenia prognoz łączonych było oszacowanie regresji liniowej, w której zmienną objaśnianą stanowią rzeczywiste kwartalne zyski operacyjne spółek, natomiast zmiennymi objaśniającymi są prognozy analityków i predykcje otrzymane z sześciu modeli autoregresyjnych. W tym przypadku selekcja regresorów (według kryterium ich istotności statystycznej) umożliwia bardziej obiektywną identyfikację optymalnej kombinacji prognoz indywidualnych (w zakresie zarówno selekcji prognoz indywidualnych, które powinny tworzyć prognozę łączoną, jak i doboru wag dla poszczególnych prognoz indywidualnych). Selekcji zmiennych objaśniających (a tym samym selekcji prognoz indywidualnych do sporządzenia prognoz łączonych) dokonano przy wykorzystaniu procedury modelowania „od ogółu do szczegółu”. W metodzie tej dokonuje się estymacji modelu zawierającego wszystkie kandydatki na zmienne egzogeniczne, a następnie weryfikuje się ich istotność statystyczną np. za pomocą testu *t*-Studenta. Analizę istotności zmiennych przeprowadzono na poziomie istotności 0,05. W pierwszym etapie selekcji spośród nieistotnych zmiennych usunięta została z modelu ta, której wartość statystyki *t*-Studenta była najniższa. Następnie dokonano reestymacji modelu bez zmiennej wykluczonej i ponownie zbadano istotność pozostałych zmiennych. Procedurę kontynuowano do momentu, kiedy w modelu pozostały jedynie zmienne istotne statystycznie. Ostatecznie w regresji pozostały trzy zmienne objaśniające, co

oznacza, iż według procedury tej prognozę łączoną powinna stanowić kombinacja prognoz analityków i prognoz otrzymanych z dwóch modeli autoregresyjnych. Wyniki oszacowanej regresji przedstawia tab. 3.

Tabela 3. Rezultaty regresji liniowej kwartalnych zysków operacyjnych spółek względem prognoz tych zysków sporządzonych przez analityków oraz otrzymanych z dwóch modeli autoregresyjnych

Zmienne modelu	Parametry*
Prognozy analityków	1,082 (37,09)
Prognozy z modelu 3	-0,090 (-2,38)
Prognozy z modelu 4	0,060 (2,49)
Współczynnik determinacji	0,851
Skorygowany wsp. determinacji	0,849
Statystyka F	1 229,84
Istotność statystyki F	0,0000
Metoda estymacji	KMNK
Postać analityczna	Liniowa
Liczba obserwacji	648

* W nawiasach podano wartości statystyk *t*-Studenta.

Źródło: opracowanie własne.

Zastosowana procedura regresji liniowej wskazała na zasadność budowy łączonych prognoz kwartalnych zysków operacyjnych polskich spółek jako kombinacji prognoz analityków oraz prognoz otrzymanych z dwóch z sześciu alternatywnych modeli autoregresyjnych: modelu 3 oraz modelu 4. Na podstawie oszacowanej regresji liniowej sporządzono prognozy łączone (stanowiły je wartości teoretyczne zmiennej objaśnianej uzyskane z oszacowanej regresji). Dla otrzymanych w ten sposób prognoz łączonych obliczono medianę bezwzględnego błędu predykcji (wyniosła ona 25,5%) i średni arytmetyczny bezwzględny błąd predykcji (wyniósł on 130,3%). Zatem zarówno mediana, jak i średnia arytmetyczna bezwzględnych błędów predykcji okazały się wyższe niż w przypadku predykcji analityków. Wskazuje to zatem, iż łączenie prognoz analityków z prognozami mechanicznymi przy wykorzystaniu przedstawionej procedury opartej na regresji liniowej nie przyczynia się do redukcji przeciętnych błędów bezwzględnych. Ponadto należy pamiętać, iż otrzymane wyniki pozwalają ocenić dokładność prognoz łączonych w próbie,

na podstawie której oszacowano regresję liniową (prognozy te stanowią wartości teoretyczne zmiennej objaśnianej z oszacowanej regresji), natomiast w rzeczywistości zachodzi konieczność szacowania regresji w oparciu na historycznych obserwacjach i budowania prognoz rzeczywistych dotyczących przyszłych obserwacji. W związku z tym należy oczekiwać, że w rzeczywistości relatywna dokładność prognoz łącznych w oparciu na regresji liniowej prognoz indywidualnych byłaby jeszcze niższa.

4. Zakończenie

W artykule dokonano porównania trafności indywidualnych, sporządzonych przez analityków giełdowych oraz otrzymanych z prostych modeli autoregresyjnych prognoz kwartalnych zysków operacyjnych polskich spółek publicznych z trafnością prognoz łączonych otrzymanych jako kombinacje prognoz analityków oraz prognoz autoregresyjnych. Analizę przeprowadzono dla 648 prognoz kwartalnego zysku operacyjnego opublikowanych przez cztery domy maklerskie w okresie od początku 2005 r. do końca 2008 r. Zastosowano dwa alternatywne podejścia do łączenia prognoz. Pierwsze bazowało na analizie korelacji liniowej między błędami względnymi prognoz analityków i prognoz autoregresyjnych (zakładając, iż redukcja błędów predykcji jest możliwa, gdy łączone są prognozy o nisko lub ujemnie skorelowanych błędach), natomiast drugie podejście było oparte na regresji liniowej rzeczywistych wartości zmiennej prognozowanej względem jej prognoz otrzymanych z kilku alternatywnych podejść prognostycznych. Badanie wykazało, iż proste łączenie prognoz analityków z predykcjami autoregresyjnymi (poprzez liczenie średniej arytmetycznej z dwóch prognoz) nie powoduje obniżenia mediany względnych błędów predykcji (mediana ta okazała się wyższa niż w przypadku prognoz analityków), jednak przyczynia się do redukcji średniego arytmetycznego błędu bezwzględnego (błąd ten okazał się niższy w przypadku prognoz analityków i wszystkich badanych modeli autoregresyjnych). Natomiast zastosowanie bardziej zaawansowanego podejścia do budowy prognoz łączonych (z wykorzystaniem regresji liniowej) nie przyczyniło się do redukcji przeciętnych błędów predykcji (mierzonych zarówno medianą, jak i średnią arytmetyczną błędów). Zatem łączenie prognoz przy wykorzystaniu równych wag dla prognoz indywidualnych wydaje się w przypadku kwartalnych zysków spółek rozwiązaniem lepszym niż poszukiwanie optymalnego układu zróżnicowanych wag. Przeprowadzone badanie wskazuje zatem, iż w odniesieniu do prognoz wyników finansowych spółek łączenie predykcji analityków z prognozami mechanicznymi jest rozwiązaniem zalecanym w sytuacjach, gdy dla wykorzystujących prognozy większe znaczenie niż minimalizacja przeciętnych błędów prognoz ma ograniczenie liczby prognoz o ponadprzeciętnie wysokich błędach [Armstrong 2001].

Literatura

- Armstrong J.S., *Principles of Forecasting: A Handbook for Researchers and Practitioners*, Kluwer Academic Publishers, Norwell 2001.
- Barassi M.R., Caporale G.M., Hall S.G., *Testing for Changes in the Long-Run Causal Structure of Cointegrated Vector Autoregressions*, Department of Economics Discussion Papers, The University of Birmingham, September 2001.
- Brown L.D., *Analyst forecasting errors and their implications for security analysis: an alternative perspective*, „Financial Analyst Journal” Jan./Feb. 1996.
- Bunn D.W., *Combining forecasts*, „European Journal of Operational Research” 1988, vol. 33.
- Chatfield R.E., Moyer R.Ch., Sisneros P.M., *The accuracy of long-term earnings forecasts for industrial firms*, „Quarterly Journal of Business and Economics” 1989, vol. 28.
- Ciccone S.J., *Analysts' Annual Forecasts and Quarterly Earnings Releases*, University of New Hampshire Working Papers, 2002.
- Dreman D., *Contrarian Investment Strategies. The Next Generations: Beat the Market by Going Against the Crowd*, Simon & Shuster 1998.
- Guerard J.B., Beidleman C.R., *Composite Earnings Forecasting Efficiency*, „Interfaces” 1987, vol. 17.
- Harris R., Conroy R., *Consensus forecasts of corporate earnings: analysts' forecasts and time-series methods*, „Management Science” 1987.
- Holmen J.S., *A note on the value of combining short-term earnings forecasts: a test of Granger and Ramanathan*, „International Journal of Forecasting” 1987, vol. 3.
- Lobo G.J., Nair R.D., *Combining judgmental and statistical forecasts: an application earnings forecasts*, „Decision Sciences” 2007, vol. 21.
- Malkiel B.G., *A Random Walk Down Wall Street. The Time-Tested Strategy for Successful Investing*, W.W. Norton & Company, 2007.
- O'Brien P., *Analysts' forecasts as earnings expectations*, „Journal of Accounting and Economics” 1988, vol. 10.
- Rothovius T., *Earnings and Analysts' Forecasts*, The American Finance Association Meeting, University of Oulu, 2008.
- Terregrossa S.J., *Combining analysts' forecasts with causal model forecasts of earnings growth*, „Applied Financial Economics” 1999, vol. 9.
- Timmermann A.G., *Forecast Combinations*, Centre for Economic Policy Research Discussion Papers, November 2005.
- Welc J., *Kwartalne wyniki finansowe spółek – prognozy analityków na tle prognoz autoregresyjnych*, referat wygłoszony na III Ogólnopolskiej Konferencji Naukowej „Modelowanie i prognozowanie zjawisk społeczno-gospodarczych”, Zakopane, 5-8 maja 2009.
- White G.I., Sondhi A.C., Fried D., *The Analysis and Use of Financial Statements*, John Wiley & Sons, 2003.

QUARTERLY FINANCIAL RESULTS OF POLISH PUBLIC COMPANIES – THE IMPACT OF COMBINING ANALYSTS FORECASTS WITH MECHANICAL PREDICTIONS ON FORECASTS ACCURACY

Summary: The forecasts of public companies' financial results constitute an essential element of valuations. In making forecasts the analysts exploit a wide range of information. However, the research of the accuracy of those forecasts is not unequivocal. Some research

indicates the superiority (as regards the accuracy) of the analysts' forecasts over the mechanical forecasts, but at the same time the results of other research point out to the higher accuracy of simple (in some cases even naïve) forecasting methods over the analysts' predictions. This suggests the possibility to reduce the forecast errors by combining predictions. The paper explores the impact of combining analysts' forecasts with autoregressive predictions on the accuracy of quarterly operating earnings forecasts. The research found that simple combining of forecasts (by the mean of simple arithmetic average of two individual forecasts) does not reduce the median absolute forecast error but it entails the reduction of arithmetic average absolute forecast errors.