



UNIWERSYTET EKONOMICZNY
W POZNANIU



Piotr Arendarski

**WYKORZYSTANIE MODELU PROBITOWEGO W PROCESIE ALOKACJI AKTYWÓW NA
MIĘDZYNARODOWYCH RYNKACH FINANSOWYCH W LATACH 2002 – 2009**

Rozprawa doktorska

Promotor:

dr hab. Wiesław Łuczyński, prof. nadzw. UEP

Wydział Gospodarki Międzynarodowej

Katedra Finansów Międzynarodowych

Poznań 2011

Spis treści

1.1. Wprowadzenie.....	6
Część pierwsza. Zagadnienia teoretyczne związane z wykorzystaniem modeli dwumianowych w procesie alokacji aktywów	
Rozdział I Teoretyczne zagadnienia związane z procesem alokacji aktywów.....	11
1.1. Założenia procesu alokacji aktywów.....	11
1.2. Charakterystyka procesu alokacji aktywów.....	14
1.3. Rebalancing w procesie alokacji aktywów.....	17
1.4. Rozróżnianie jakości klas aktywów.....	17
Rozdział II Modele zmiennych jakościowych.....	19
2.1. Podstawowe pojęcia.....	19
2.2. Modele dwumianowe.....	21
2.3. Modele dwumianowe w zastosowaniu do analizy finansowych szeregów czasowych.....	26
2.3.1. Teoria prognozowania i analiza zdarzeń na rynkach kapitałowych.....	26
2.3.2. Modele mikroekonometryczne w analizach giełdowych szeregów czasowych.....	29
Część druga. Empiryczna weryfikacja wykorzystania modelu probitowego w procesie alokacji pomiędzy grupy aktywów	
Rozdział III Wykorzystanie modelu probitowego w procesie alokacji aktywów między indeksy Wig20 i sWig80.....	31
3.1. Charakterystyka opisowa indeksów Wig20 i sWig80.....	31
3.2. Analiza dotychczasowej literatury.....	33
3.3. Cel pracy, hipotezy badawcze.....	34
3.4. Metodologia i wyniki badań.....	35
3.5. Analiza wyników.....	55
3.5.1. Analiza zmiennych wpływających na przyszłe zachowanie się spreadu Wig20-sWig80.....	55
3.5.2. Analiza skuteczności modeli probitowych.....	57

3.5.3. Analiza przyczyn skuteczności zaprezentowanych modeli	57
Rozdział IV Wykorzystanie modelu probitowego w procesie alokacji aktywów między indeksy S&P 500 i Dow Jones Industrial Average (DJIA)	59
4.1. Charakterystyka opisowa indeksów SP 500 i DJIA	59
4.2. Hipotezy i cele badawcze.....	60
4.3. Metodologia i wyniki badań	61
4.4. Analiza wyników	68
Rozdział V Wykorzystanie modelu probitowego w procesie alokacji aktywów między Złoto, S&P 500 i Dolar / Jen.....	69
5.1. Wprowadzenie. Analiza dotychczasowej literatury.....	69
5.2. Analiza powiązań między Złotem, S&P 500 i Dolar / Jen	70
5.3. Cel i hipotezy badawcze	75
5.4. Metodologia i wyniki badań	76
5.4.1. Estymacja modeli dla spreadu Złoto – S&P500	80
5.4.2. Estymacja modeli dla spreadu Złoto – Dolar / Jen	92
5.4.3. Estymacja modeli dla spreadu Złoto – S&P500 – Dolar / Jen	102
5.4.4. Metodologia budowy strategii inwestycyjnej.....	111
5.4.4.1. Metodologia i wyniki badań strategii dla poszczególnych spreadów	112
5.4.4.2. Metodologia i wyniki badań dla strategii głównej	117
5.4.4.3. Ujęcie strategii głównej z perspektywy polskiego inwestora	123
5.5. Wyniki badań nad poszczególnymi kryteriami dobroci modelu	124
5.6. Wyniki badań nad istotnością zmiennych opisujących modele spreadów	125
5.7. Analiza wyników	130
5.7.1. Test Simsa.....	130
5.7.2. Analiza skuteczności modeli probitowych	131
5.7.3. Analiza kryteriów dobroci modeli probitowych.....	132
5.7.4. Analiza istotności zmiennych opisujących spready.....	133

5.7.5. Analiza problemów poruszonych na wstępie rozdziału	133
Rozdział VI Wykorzystanie modelu probitowego w procesie alokacji aktywów między spółki z indeksu sWig80.....	135
6.1. Wprowadzenie i przegląd dotychczasowych badań	135
6.2. Cel i hipotezy badawcze	137
6.3. Metodologia badań związanych z wykorzystaniem modelu probitowego	137
6.4. Metodologia strategii momentum.....	149
6.5. Wyniki badań. Koncepcja Probit Portfolio.....	151
6.6. Analiza wyników	155
Podsumowanie.....	158
Spis tabel.....	162
Spis wykresów	165
Spis obrazów.....	166
Spis diagramów	167
Bibliografia	167

Wstęp.

Badania polegające na poszukiwaniu mechanizmów wyznaczających ceny papierów wartościowych oraz prognozowania cen walorów, a także konstruowaniu portfeli inwestycyjnych mają bogatą i udokumentowaną historię. Od samego początku istnienia giełd człowiek starał się odgadnąć przyszłe zachowanie się cen poszczególnych aktywów. W wyniku tych dociekań powstało wiele teorii i modeli opisujących zachowanie się rynków finansowych. Jednym z pilnie badanych zjawisk była teoria alokacji aktywów. Asumptem do rozwoju teorii alokacji aktywów były prace Markowitza nad dywersyfikacją i ryzykiem portfela papierów wartościowych. Jednak teoria alokacji aktywów to coś więcej niż optymalizacja danego portfela papierów wartościowych względem ryzyka i stopy zwrotu. Kluczowym zagadnieniem w teorii alokacji aktywów jest dobór składników do portfela papierów wartościowych. Łączy się to z głównym motywem inwestowania, który można określić jako wzrost siły nabywczej kapitału.

Rozwój rynków finansowych i możliwości inwestycyjnych sprawia, że ceny instrumentów finansowych zależą od coraz większej ilości czynników. Aktualnie mamy coraz większe możliwości monitorowania i analizowania coraz większej ilości cen aktywów. Taki ogrom informacji sprawia, że badacz powinien zważyć istotność wpływu poszczególnych czynników na analizowane zdarzenie, aby mógł w sposób prawidłowy ocenić przyszłe zachowanie się poszczególnych klas aktywów. Z pomocą przychodzą metody ilościowe wykorzystywane w ekonomii. Szczególnie użyteczne przy podejmowaniu wszelkiego rodzaju decyzji zerojedynkowych są modele dwumianowe.

Zastosowanie metody wykorzystania modeli dwumianowych w teorii alokacji aktywów nie jest koncepcją nową. Pierwotnym obszarem wykorzystania tego typu modeli są zjawiska mikroekonomii, czyli analiza zachowań jednostki w otoczeniu gospodarczo – społecznym. Jednak z biegiem lat i rozwojem rynków kapitałowych stały się one popularne również w badaniach dotyczących teorii alokacji aktywów. Literaturę przedmiotu można podzielić na klasy aktywów, których badanie dotyczy. Głównym zainteresowaniem badaczy jest alokacja między indeksy giełdowe. Do głównych pozycji z tego tematu można zaliczyć prace Arshanapalli, Switzer i Hung (2004), Gokani i Todorovic (2006). Drugim podejściem jest wybór między stanami na rynku giełdowym: hossa, bessy, konsolidacja. Temat ten podjęli między innymi Liu, Resnick i Shoemsmith G. (2004), Fan, Lau i Leung (1998), Nam i Branch (1994). Kolejnym podejściem jest wykorzystanie modeli dwumianowych do klasyfikacji spółek giełdowych. Wśród autorów prac z tego zakresu można wskazać Jaouida Elleuch J., Trabelsi L. (2009), Arendarski (2009), Morton i

Shane (1998). Badania przytoczone powyżej przeprowadzono głównie na rozwiniętych rynkach finansowych, a prace dostępne są tylko w języku angielskim. W zbiorach polskiej literatury brakuje kompleksowego podejścia do wykorzystania modeli dwumianowych w teorii alokacji aktywów.

Głównym celem pracy jest odpowiedź na pytanie czy model probitowy może być efektywnym narzędziem w procesie alokacji aktywów.

Na podstawie celu głównego pracy skonstruowano hipotezy badawcze, które brzmią następująco:

- Krótkoterminowe różnice w zmianach stóp zwrotu między indeksami dużych i małych spółek mogą być lepiej wyjaśniane przez model probitowy w porównaniu ze strategią momentum oraz równo ważoną strategią kup i trzymaj.
- Krótkoterminowe różnice w zmianach stóp zwrotu między Złoto – S&P 500, Złoto – Dolar/Jen oraz S&P 500 – Dolar/Jen mogą być lepiej wyjaśniane przez model probitowy w porównaniu ze strategią momentum oraz strategią pasywną.
- Model probitowy może być efektywnym narzędziem w procesie wyboru spółek do portfela na podstawie zmian wskaźników finansowych.

Badania obejmują szeregi czasowe za okres od 1995 roku do 2009 roku.

W badaniu wykorzystano następujące metody:

- Model probitowy
 - Główna metoda mająca na celu rozwiązać problem badawczy. Model probitowy będzie zwracał wagi, jakie należy przypisać danemu aktywowi w portfelu w danym okresie.
- Metoda budowy portfela aktywów oparta na potrójnym modelu probitowym „Probit Portfolio”
- Aplikacja „Probit Optimizer”
- Test Simsa
 - Test Simsa jest jednym z testów przyczynowości w sensie Grangera. Test ten będzie badał czy dana objaśniająca ma istotny wpływ na zmienną objaśnianą. Był on zarazem kryterium wyboru zmiennych objaśniających do dalszej analizy.
- Elementy analizy statystycznej

- Średnia arytmetyczna służyła do wyznaczania stopy zwrotu z danego aktywa lub portfela aktywów.
- Odchylenie standardowe było podstawową miarą zmienności, za pomocą której określano ryzyko inwestycji w dane aktywo lub portfel aktywów.

Praca jest podzielona na dwie części.

Część pierwsza składa się z dwóch rozdziałów opisujących zagadnienia teoretyczne związane z wykorzystaniem modeli dwumianowych w procesie alokacji aktywów.

Rozdział pierwszy opisuje teoretyczne aspekty związane z teorią alokacji aktywów. Rozdział ten jest wprowadzeniem w zagadnienia dotyczące teorii alokacji aktywów. Autor uwagę skupia na podstawowych zagadnieniach, które prezentują znaczenie oraz fundamenty procesu alokacji aktywów.

Rozdział drugi opisuje teoretyczne aspekty związane z modelami zmiennych jakościowych. W rozdziale tym zostały przedstawione podstawowe pojęcia z zakresu modelowania zmiennych jakościowych oraz główne rodzaje stosowanych modeli, jak i systematyka modeli zmiennych jakościowych i ograniczonych oraz zostało zdefiniowane pojęcie zmiennej jakościowej. Dodatkowo w rozdziale tym autor opisuje modele dwumianowe w zastosowaniu do analizy finansowych szeregów czasowych. Rozdział ten przedstawia możliwości i wykorzystanie modeli dwumianowych do analizy niektórych finansowych szeregów czasowych. Chodzi przede wszystkim o analizę wydarzeń na rynkach kapitałowych, czyli przewidywanie cenowych skutków zdarzeń, takich jak ogłoszenie wyników finansowych, planowana emisja akcji, czy informacja o projektowanym połączeniu spółek.

Część druga składa się z czterech rozdziałów i opisuje badania które dotyczą empirycznej weryfikacji wykorzystania modelu probitowego w procesie alokacji pomiędzy grupy aktywów.

W rozdziale trzecim autor opisuje i bada proces alokacji aktywów pomiędzy: indeksy sWig80 i Wig20. Na początku dokonano wprowadzenia do problematyki badania. Poprzez opisanie zależności między indeksami Wig20 i sWig80 i ich charakterystyk, autor wyjaśnił powody podjęcia tego zagadnienia. Dodatkowo zaprezentował przegląd literatury prezentując dwie koncepcje podejścia do tematu wyjaśniania zależności między indeksami małych i dużych spółek. Pierwsze polega na zastosowaniu modeli dwumianowych, natomiast w drugim głównym narzędziem jest strategia momentum. W części empirycznej autor podaje cele badania i opisuje metodologię badań. Prace rozpoczęto od wyboru zbioru zmiennych objaśniających, które podzielono na zmienne niezależne oraz zmienne typu spread opisujące wzajemne relacje między

dwoma instrumentami finansowymi. Po przeprowadzeniu testów Simsa na istnienie przyczynowości między zmiennymi objaśniającymi, a zmienną zależną, autor buduje modele wykorzystując metody krokowe; wsteczną i postępującą. Wybrane modele są efektywne według wybranych przez autora kryteriów dobroci (dopasowania) modelu. Następnie budowane są prognozy dynamiczne i osiągnięte wyniki są porównywane ze strategiami momentu oraz pasywną strategią typu „kup i trzymaj”. Ostatecznie autor odpowiada na pytania postawione na początku pracy, dokonuje analizy osiągniętych wyników oraz analizuje przyczyny odchylenia na spreadzie między indeksami Wig20 i sWig80.

W czwartym rozdziale autor opisuje proces alokacji aktywów pomiędzy indeksy S&P 500 i DJIA oraz przedstawia aplikację „Probit Optimizer”. Głównym celem tego podrozdziału jest prezentacja aplikacji „Probit Optimizer” (PO), która w sposób automatyczny estymuje wszystkie możliwe modele z danego k-elementowego zbioru zmiennych objaśniających sprawdzając, który z nich ma największą moc prognostyczną.

Rozdział piąty opisuje proces alokacji aktywów pomiędzy Złoto, S&P500 i Dolar / Jen. W rozdziale tym autor dokonał rozbudowy modelu budując potrójny model probitowy wyjaśniający odchylenia między trzema spreadami : Złoto – S&P 500, Złoto – Dolar/Jen oraz S&P 500 – Dolar/Jen. Dodatkowo autor opisał metodologię budowy 3 modeli rozpoczynając od testów Simsa, kończąc na wyznaczeniu efektywnych modeli dla każdego spreadu. Następnie budowano prognozy dla poszczególnych spreadów i wyniki tych prognoz konfrontowano ze strategiami momentum oraz strategią pasywną. Następnie zbudowano potrójny model probitowy, który zwracał osobne wagi w portfelu dla trzech instrumentów: Złoto, indeks S&P 500 oraz waluta Dolar / Jen. Dokonano również badań nad poszczególnymi kryteriami dopasowania modelu i porównano wyniki strategii opartych na poszczególnych kryteriach. Dokonano również analizy istotności poszczególnych zmiennych w poszczególnych modelach dla spreadów. Wyniki istotności zmiennych w modelach probitowych porównano do wyników istotności w testach Simsa oraz przeprowadzono symulację strategii inwestycyjnej opartej na najbardziej istotnych zmiennych. W końcu dokonano analizy przeprowadzonych badań, dostarczono odpowiedzi na hipotezy zawarte we wstępie oraz opisano zależności występujące między złotem, indeksem S&P500 oraz walutą Dolar / Jen, które autor dostrzegł w trakcie badań w tym obszarze badawczym.

Rozdział szósty opisuje proces alokacji aktywów pomiędzy spółki z indeksu sWig80. Przeprowadzono przegląd literatury przedmiotu w nawiązaniu do pól silnej teorii efektywności rynków. Przedstawienie hipotez badawczych rozpoczęły rozważania na temat możliwości zastosowania modelu probitowego do oceny procedury wyceny wartości spółki względem indeksu na podstawie zmian wskaźników finansowych. Następnie opisano metodologię badań. Po estymacji modeli probitowych metodą największej wiarygodności dokonano selekcji modeli metodą regresji krokowej wstecznej ze względu na przyjęte kryteria dopasowania modelu. Prognozowano czy dana spółka osiągnie stopę wyższą niż indeks sWig80. W toku badań powstały 3 portfele reprezentujące 3 efektywne modele według kryteriów dobroci modelu. Dodatkowo w rozdziale szóstym autor opisał autorską strategię momentum, wykorzystującą zbiór treningowy obserwacji modelu probitowego. Następnie porównano obie strategie alokacji kapitału do strategii pasywnych. Ostatecznie przedstawiono wyniki i wnioski wynikające z badań nad możliwościami zastosowania modelu probitowego do wyceny spółek z indeksu sWig80.

Zakończenie pracy zawiera wnioski końcowe i weryfikację hipotezy głównej.

Szczególne podziękowania kieruje do mojego promotora dr hab. Wiesława Łuczyńskiego za chętnie okazywaną wszechstronną pomoc, cenne wskazówki, a przede wszystkim za cierpliwość i wyrozumiałość.

Rozdział I

Teoretyczne zagadnienia związane z procesem alokacji aktywów

1.1. Założenia procesu alokacji aktywów

Proces Alokacji Aktywów (PAA) może mieć różne znaczenie dla różnych typów inwestorów. Dla wielu profesjonalnych inwestorów, PAA często znaczy obliczanie stopy zwrotu, odchylenia standardowego i badania korelacji między różnymi klasami aktywów. Następnie następuje zoptymalizowanie tych zmiennych za pomocą metod portfelowych opartych na stosunku zysku do ryzyka, wybranie odpowiednich klas aktywów i wreszcie zaimplementowanie PAA w wersji odpowiadającej celom, preferencjom i ograniczeniom profesjonalnego inwestora.

Natomiast dla indywidualnego inwestora, PAA może nie zawierać tych kalkulacji. Zazwyczaj inwestorzy indywidualni muszą mieć na uwadze takie czynniki jak: podatek nakładany na zyski kapitałowe, indywidualne motywacje i osobiste czynniki.

Dla wielu inwestorów PAA ma głębsze znaczenie niż tylko matematyczna optymalizacja stóp zwrotu, odchylenia standardowego i korelacji. Bardzo istotnym czynnikiem w PAA jest łącznie charakterystyk poszczególnych typów aktywów w celu stworzenia portfela aktywów o znacznie lepszym stosunku zwrot-ryzyko niż każdy z pojedynczych aktywów wziętych osobno. Można by to nazwać efektem synergii. Kolejnym czynnikiem jest rozpoznanie własnych potrzeb zrównoważenia procesu inwestycyjnego, mając na myśli horyzont czasowy, metody ochrony kapitału czy oczekiwane źródła dochodów kapitałowych. PAA to także ustalenie minimalnych i maksymalnych ograniczeń, aby zapewnić wystarczającą reprezentację danego aktywów, jednak nie doprowadzić do sytuacji, gdy na dane aktywo będzie zbyt duża ekspozycja (ryzyko). W końcu ważnym czynnikiem jest dywersyfikacja aktywów, która ma na celu zwiększenie wskaźnika zysk/ryzyko¹.

Fundamentalne pojęcia w procesie alokacji aktywów.

Na gruncie nauki o finansach wykształciły się podstawowe założenia stanowiące swego rodzaju fundamenty PAA. Można je podzielić na 3 grupy: związane z danym aktywem, związane z rynkiem, oraz związane z inwestorem.

¹ Kao D. Schumaker R.D. [1999], Equity Style Timing, Financial Analysts Journal, s. 3

Fundamentalne aspekty procesu alokacji aktywów związane z danym aktywem.

Wśród wielu aspektów procesu alokacji aktywów związanych z danym aktywem można wyróżnić najistotniejsze z punktu widzenia inwestorów, do których należą:

- Wybór klasy aktywów
- Ocena statystyczna charakterystyki danego aktywów
- Ocena globalna danego aktywów

Biorąc pod uwagę wybór klasy aktywów, należy zdecydować, które z klas będą brane pod uwagę w konstruowaniu portfela oraz które będą z niego wykluczone. Przykładowo, w ramach klasy aktywów o stałym dochodzie, inwestor musi zdecydować czy włączyć do portfela aktywa podlegające opodatkowaniu, aktywa niepodlegające opodatkowaniu czy może umieścić w portfelu oba rodzaje. Dodatkowo można decydować, o jakości aktywów (obligacje rządowe, obligacje komunalne), terminie wykupu (krótkoterminowe, długoterminowe, z opcją natychmiastowego wykupu czy może wszystkie rodzaje). Dodatkowo, w szeroko rozumianej klasie aktywów, należy wziąć pod uwagę jak wiele czasu poświęcić alokacji aktywów, ile jest kapitału dostępnego, jaki profil inwestycyjny, jakie są preferencje i awersje do ryzyka oraz inne kryteria włączając w to koszty transakcyjne, płynność.

Oceniając charakterystykę danego aktywów należy zbadać jego historię i ocenić jego przeszłe charakterystyki dotyczące stopy zwrotu, odchylenie standardowe i korelacje. Należy również wziąć pod uwagę czy charakterystyki dotyczące stopy zwrotu, wariacji i korelacji będą się przyszłości zmieniać, czy historycznie są na najwyższym poziomie, najniższym czy może średnim.

Globalna ocena danego aktywów jest wymieniana, jako ostatnia, jednak nie oznacza to, że jest najmniej ważna. Wręcz odwrotnie, ocena ta ma kluczowe znaczenie w PAA. Klasy aktywów powinny być oceniane według kryteriów takich jak: aspekty ekonomiczno-finansowe, wycena w odniesieniu do historycznych poziomów i w relacji do innych aktywów oraz psychologiczne, techniczne i płynnościowe czynniki oddziałujące na cenę aktywów.

Fundamentalne aspekty procesu alokacji aktywów związane z danym rynkiem.

- Kalkulacja dywergencji
- Analiza scenariuszowa
- Szacowanie ryzyka

Analizę dywergencji należy przeprowadzić aby sprawdzić aktualną cenę aktywa, poziom wyceny w stosunku do aktualnego trendu oraz jak odchyła się cena lub wycena od jej długoterminowej średniej.

Analizę scenariuszową należy przeprowadzić, aby ocenić prawdopodobieństwo wystąpienia określonych warunków rynkowych. Wskazać, jakie mogą być najgorsze lub najlepsze, skutki danego zdarzenia. Taka analiza sprawia, że inwestor może się przygotować psychicznie na mniej spodziewane wydarzenia na rynku.

Szacowanie ryzyka, ocena ryzyka jak i kontrola ryzyka powinny odgrywać kluczową rolę w PAA. Wśród najbardziej popularnych miar ryzyka można między innymi wymienić: odchylenie standardowe stóp zwrotu, najgorszy możliwy scenariusz, rozumiany, jako największa możliwa strata w ciągu dnia, tygodnia, czy miesiąca, na jaką inwestor zarówno pod względem mentalnym jak i materialnym powinien być przygotowany.

Fundamentalne aspekty procesu alokacji aktywów związane z danym inwestorem.

Do głównych aspektów o podłożu fundamentalnym związanych z procesem alokacji aktywów należą:

- Przegląd percepcji procesu PAA przez pryzmat celów i środków
- Analiza efektywności modeli rynkowych
- Trzeźwa ocena sytuacji

Proces Taktycznej Alokacji Aktywów (TAA) wiąże się ze zbadaniem kluczowych aspektów dotyczących sytuacji samego inwestora, do których należą: z jednej strony cele inwestora, jego doświadczenie, mentalność, z drugiej strony, jego sytuacja majątkowa, obecna i przyszła sytuacja rodzinna oraz prognozowane przepływy finansowe, wreszcie należy rozważyć horyzont inwestycyjny, na jaki aktywa będą ulokowane.

Modele inwestycyjne są przydatnym narzędziem do w ramach PAA. Należy jednak zwrócić uwagę na sytuację rynkową, w jakiej się znajdują i ocenić, kiedy dane modele są przydatne i możliwe do aplikacji oraz kiedy te same modele mają ograniczoną wartość. Być może najważniejszą cechą inwestora jest rozsądna i realistyczna ocena sytuacji panującej na rynku. Aby do takiej sytuacji doprowadzić, inwestor powinien zachować zdrowy rozsądek w sytuacjach ekstremalnych na rynku, nie podejmować decyzji pod wpływem emocji².

² Darst D.,A. [2008], Art of asset allocation, McGorw & Hill, Nowy Jork, s. 56-57

1.2. Charakterystyka procesu alokacji aktywów.

Typy procesu alokacji aktywów.

Typy alokacji aktywów mogą być klasyfikowane ze względu na:

- Styl
- Orientację
- Kryteria tworzenia portfela aktywów

Styl alokacji aktywów może być konserwatywny, umiarkowany oraz agresywny. Konserwatywnym stylem mogą być inwestycje w aktywa o wysokiej jakości (obligacje i bony skarbowe) w stabilnym otoczeniu makroekonomicznym, na rynkach o niskiej inflacji. Jednak te same aktywa mogą być również uważane za ryzykowne na wysoce zmiennych rynkach finansowych z wysoką inflacją i szerokim zakresem wahań stóp procentowych jak i cen obligacji.

Konserwatywny styl charakteryzuje się relatywnie niskim poziomem ekspozycji na akcje i instrumenty takie jak papiery dłużne państw rozwijających się, fundusze hedgingowe, nieruchomości, fundusze, venture capital, waluty oraz wysokim popytem na gotówkę i krótkoterminowe inwestycje, instrumenty o stałym dochodzie oraz inwestycje krajowe.

Kolejną cechą dotyczącą stylu alokacji aktywów jest zachowanie się portfela aktywów. Generalnie konserwatywny styl powinien skutkować niską zmiennością portfela aktywów, mierzoną wariancją, oraz przynosić w proporcji wyższe dochody z dywidend oraz odsetek niż z zysków na kapitale. Z kolei odwrotna sytuacja ma miejsce w przypadku agresywnego stylu. Portfel aktywów wówczas generalnie jest narażony na wysokie wahania i większą część zysków czerpie z fluktuacji kapitału niż z dywidend i odsetek.

Rozważając orientację czy nastawienie do procesu alokacji aktywów należy zwrócić uwagę na to, że można się spotkać z trzema podejściami. Według D.A. Darst (2008, s. 26) strategiczna alokacja aktywów (SAA) ma za zadanie ustalić długoterminowy skład aktywów z relatywnie niskim poziomem zmienności krótkoterminowych zmian na rynku. Strategiczna alokacja aktywów powinna odzwierciedlać długoterminową perspektywę względem rynków finansowych i konkretnego aktywa. Ten typ alokacji aktywów charakteryzuje się niewielką i nieczęstą rotacją portfela aktywów. Jeżeli jednak zmiany składu aktywów w portfelu mają miejsce ma to zazwyczaj związek ze zmianami w profilu ryzyka danego inwestora, celami dotyczącymi wysokości stopy zwrotu, zmianami oczekiwań odnośnie stóp zwrotu, wariancji i korelacji posiadanych aktywów lub potencjalnych kandydatów na aktywa tworzące skład portfela.

Wreszcie taką przyczyną może być pojawienie się nowych klas aktywów na rynku. Natomiast Schweser (2008, s. 120) w swoim opracowaniu uważa, że SAA jest w swojej naturze strategią długoterminową, natomiast krótkoterminowe odchylenia od strategicznych założeń mogą być oparte na krótkoterminowych oczekiwaniach rynkowych i być rezultatem aktywnej alokacji aktywów. Każda klasa aktywów posiada swoje systematyczne ryzyko i SAA jest działaniem, który ma na celu osiągnąć pożądaną ekspozycję na systematyczne ryzyko poprzez określenie wag każdej z poszczególnych klas aktywów. Każde z klas aktywów reprezentuje relatywnie małą inwestycję z podobnym czynnikiem systematycznego ryzyka. Ekspozycja na konkretne klasy aktywów w różnych proporcjach pozwala inwestorom monitorować i kontrolować ich ekspozycję na ryzyko systematyczne.

Kolejnym podejściem do problemu orientacji w PAA jest taktyczna alokacja aktywów, która, według Darsta przybiera inne formy i służy innym celom niż SAA. Podstawową różnicą między obiema metodami jest horyzont czasowy, który w procesie TAA wynosi średnio rok, natomiast powszechnie jest dokonywanie zmian w portfelu aktywów, co kwartał, co miesiąc czy nawet, co tydzień³. TAA jest wykorzystywana głównie, gdy inwestor ma przeświadczenie, że dane aktywo jest aktualnie przewartościowane lub niedowartościowane w krótkim lub średnim okresie. W pewnych przypadkach inwestor może użyć kontraktów futures, opcji i innych derywatów, aby dostosować swoją ekspozycję na dane aktywo lub aktywa w krótkim okresie. Proces TAA wymaga od inwestora posiadania dobrego wyczucia ceny danego aktywa, oportunistycznej natury taktycznej alokacji aktywów, specjalnej formy taktycznego zarządzania ryzykiem, która powinna zawierać alerty cenowe i zlecenia typu stop-loss⁴.

Podobne definicje dla obu orientacji dostarcza Hudson (2009, s.2), który uważa, że SAA jest stworzona, aby zaoferować inwestorowi możliwie najwyższą stopę zwrotu w ramach tolerowanego przez niego ryzyka w długim okresie. W przeciwieństwie do TAA, która odnosi się do zmian w strukturze portfela aktywów w krótkim i długim czasie w odpowiedzi na zmiany wartości różnych klas aktywów w celu podwyższenia stopy zwrotu.

Mając na uwadze metodologię wyboru aktywów do portfela można posłużyć się metodami ilościowymi, jakościowymi oraz kombinacją obu metod. Używając metod ilościowych należy poczynić założenia dotyczące przyszłej stopy zwrotu i ryzyka dla danych klas aktywów, jak i korelacji między poszczególnymi grupami aktywów. Punktem wyjścia do dobrze opracowanej

³ Darst D.,A. [2008] *Art ... op. cit.*, s.65

⁴ Lee W.[2000] *Theory and Methodology of Tactical Asset Allocation*, Frank J. Fabozzi, s.69

analizy może być przegląd historycznych stóp zwrotu, wariacji czy korelacji za okres od 5 do 30 lat. Ilościowe podejście wymaga optymalizacji tychże parametrów w taki sposób, aby można było wyznaczyć linię efektywną pokazującą portfele minimalnego ryzyka przy danej stopie zwrotu oraz portfele maksymalizujące stopę zwrotu przy danym poziomie ryzyka. Podobne podejście do zagadnienia prezentuje Schweser, który uważa, że TAA jest rezultatem aktywnego zarządzania w czasie, gdy gracze odchodzą od strategicznej alokacji aktywów, aby wykorzystać krótkoterminowe okazje na rynku. W ten sposób TAA wprowadza dodatkowe ryzyko, które powinno być usprawiedliwione wyższą stopą zwrotu.

Podejście jakościowe do PAA może odgrywać pomocniczą rolę w podejściu ilościowym, jak i być jedynym kryterium wyboru aktywów. Jakościowe elementy PAA polegają na analizie historycznych danych, wykresów, statystycznych narzędzi i innych modeli. Jednak jest trudno określić, które elementy podejścia, do PAA są definitywnie zarezerwowane dla podejścia ilościowego, a które dla jakościowego. Generalną zasadą jest, że jakościowe podejście analizuje miary fundamentalne, takie jak wskaźniki ekonomiczne, prognozy zysków, politykę pieniężną, zmiany w wynagrodzeniach, ceny, trendy w produkcji przemysłowej oraz dotyczące wyceny, do których należą takie miary jak referencyjna stopa procentowa, nachylenie krzywej dochodowości, wskaźnik cena do zysku. Dodatkowo można też wyróżnić miary psychologiczno-techniczno-płynnościowe, które odpowiadają za sentyment inwestorów, płynność na rynku, wartość wolumenu obrotów. Syntetyczne zestawienie charakterystyk procesu alokacji aktywów zawiera tabela 1.

Tabela 1. Typy procesu alokacji aktywów.

Styl	Orientacja	Kryteria tworzenia portfela aktywów
Konserwatywny	Strategiczna	Ilościowe
Umiarkowany	Mieszana	Mieszane
Agresywny	Taktyczna	Jakościowe

Źródło: Opracowanie własne na podstawie Darst D.,A. [2008] *Art of asset allocation*, McGorw & Hill, Nowy Jork, s. 36

1.3. Rebalancing w procesie alokacji aktywów.

Rebalancing w procesie alokacji aktywów lub rebalancing portfela aktywów odnosi się do procesu sprzedaży części aktywów i zakupu innych, zazwyczaj w celu zapewnienia zgodności ogólnego składu portfela z konkretną polityką dotyczącą alokacji aktywów lub zamierzonymi wagami danych aktywów w portfelu. Potrzeba rebalansingu w PAA wywodzi się z przeświadczenia inwestora, że stopy zwrotu w dane aktywa powrócą do swojej średniej. Często, bowiem się zdarza, że w portfelu znajdują się aktywa, które, przykładowo, osiągnęły stopę zwrotu znacznie wyższą od średniej historycznej dla danego okresu i inwestor spodziewa się, że nastąpi zwrot w kierunku średniej. Kolejnym argumentem przemawiającym za stosowaniem rebalansingu w PAA jest potrzeba odpowiedniej dywersyfikacji aktywów. W tym znaczeniu rebalancing polega na polepszeniu relacji „zysk do ryzyka” przez kupienie określonej ilości aktywów po niskich cenach i sprzedanie ich po cenach wysokich⁵.

Pośród wielu możliwych metod rebalansingu w PAA najczęściej stosowane są trzy metody. Jedną z nich polega na albo sprzedawaniu aktywów, które zachowują się lepiej od rynku lub względem innych aktywów albo kupowaniu aktywów, które zachowują się słabiej od rynku lub względem innych aktywów. Strategie tego typu należą do grupy strategii momentum. Kolejną strategią momentum i zarazem metodą rebalansingu w PAA jest strategia, która polega na sprzedawaniu aktywów, które zachowują się gorzej od rynku lub względem innych aktywów, kupowanie aktywów, które zachowują się lepiej od rynku lub względem innych aktywów. Wreszcie trzecią metodą rebalansingu w PAA jest zachowanie się neutralnie względem zmieniających się wag w portfelu, w ten sposób aktywa, których stopy zwrotu są wyższe względem innych instrumentów, będą automatycznie bilansować się w taki sposób, że ich waga w portfelu będzie wyższa.

1.4. Rozróżnianie jakości klas aktywów.

Jedną z najważniejszych umiejętności w PAA jest rozróżnianie klas aktywów. Ma to na celu posortowanie aktywów na grupy według ich charakterystyk dotyczących stopy zwrotu i odchylenia standardowego. Ważne jest, aby rozważyć czy klasy aktywów są odpowiednio zdefiniowane oraz czy klasy aktywów w danym portfelu będą w stanie zagwarantować odpowiednią dywersyfikację ryzyka. Istotne jest, aby poszczególne klasy aktywów nie były ze

⁵ Darst D.,A. [2008] *Art ... op. cit.*, s. 78

sobą silnie skorelowane. Schweser uważa, że klasy aktywów są poprawnie wyspecyfikowane, jeżeli:

- Aktywa w swojej klasie są podobne pod względem opisu jak i statystycznych właściwości.
- Nie są wysoko skorelowane
- Jedno aktywo nie może być sklasyfikowane w wielu klasach
- Pokrywają większość możliwych aktywów inwestycyjnych

Klasy aktywów można podzielić na 4 główne grupy:

- Papiery udziałowe (Akcje)
- Papiery o stałym dochodzie
- Inwestycje alternatywne
- Instrumenty rynku pieniężnego

Tabela 2 w sposób syntetyczny przedstawia 4 klasy aktywów wraz z 17 podklasami aktywów.

Tabela 2. Główne klasy aktywów.

Papiery udziałowe (Akcje)	Papiery o stałym dochodzie	Inwestycje alternatywne	Instrumenty rynku pieniężnego
- Akcje krajów rozwiniętych - Akcje krajów rozwijających	- Papiery dłużne o stałym dochodzie państw rozwiniętych - Papiery dłużne o stałym dochodzie państw rozwijających się - Papiery dłużne wysoko oprocentowane - Obligacje zamienne	- Private Equity i Venture Capital - Towary - Nieruchomości - Fundusze hedgingowe - Metale szlachetne i złoto - Fundusze futures rynków towarowych - Sztuka	- Gotówka i jej ekwiwalenty

Źródło: Opracowanie własne na podstawie: Darst D.,A. [2008] *Art ...* op. cit.

Rozdział II

Modele zmiennych jakościowych.

2.1. Podstawowe pojęcia.

Jedną z definicji przyjmuje, że modele zmiennych jakościowych oznaczają w ekonometrii klasę modeli, w których losowe zmienne endogeniczne przyjmują wartości dyskretne.

To są takie zmienne Y , których wartości mają postać niemierzalną. W tej sytuacji klasyczny model regresji nie jest specjalnie użyteczny.

Jeśli chodzi o zmienne objaśniające (X), to nadal warto posługiwać się ich kombinacją liniową, jak w klasycznym jednorównaniowym modelu. Jednak obecnie ta liniowa kombinacja powinna być powiązana ze zmienną objaśnianą za pomocą pewnej funkcji o postaci nieliniowej. Dzieje się tak, ponieważ „kategorie” zmiennej Y nie dają się sensownie wyrazić liczbowo, można jedynie mówić o prawdopodobieństwie, że dla pewnej kombinacji zmiennych X zmienna Y znajdzie się w pewnej „kategorii”. Przyjęty w modelu rozkład prawdopodobieństwa decyduje właśnie o postaci wspomnianej nieliniowej funkcji.

Modele zmiennych jakościowych należą do mikroekonometrii, ponieważ są zazwyczaj stosowane do mikrodanych czyli danych indywidualnych: o pracownikach, o bezrobotnych, o klientach banku, o firmach, o obywatelach, czy o osobach ankietowanych.

Mogą mieć postać: binarną (na ogół zerojedynekową), uporządkowanej klasyfikacji, nieuporządkowanej klasyfikacji. Konstrukcja zmiennych jakościowych staje się bardziej skomplikowana, w przypadku występowania heteroskedastyczności i autokorelacji składnika losowego modelu w przypadku więcej niż jednej zmiennej jakościowej należy rozważyć uwzględnienie ich łącznego efektu na zmienną objaśnianą; interakcyjna zmienna jakościowa ma charakter multiplikatywny i pozwala sprawdzić, czy łączne występowanie dwóch cech wzmacnia ich indywidualny wpływ na zmienną objaśnianą⁶.

Każdą zmienną jakościową można sprowadzić do zmiennej 0-1.

Y - rozważana zmienna losowa (jako realizacja bądź nie danego wariantu):

$Y = 1$, gdy realizacja

$Y = 0$, gdy negacja

o rozkładzie:

$P(Y=1) = p$

⁶ http://akson.sgh.waw.pl/~mtomczyk/Slajdy_06.pdf - Wykłady dr Emilii Tomczyk, Szkoła Główna Handlowa

$$P(Y=0)=1-p$$

Oczekiwane wartości zmiennej Y:

$$E(Y) = 1 \cdot p + 0 \cdot q = p,$$

gdzie:

$$p = F(b_0 + b_1 X_1 + \dots + b_k X_k + \varepsilon)$$

- X_1, \dots, X_k – zmienne objaśniające, wpływające na zmienną jakościową Y,
- b_0, b_1, \dots, b_k – parametry,
- F – kombinacja liniowa zm. X_1, X_2, \dots, X_k oraz składnika losowego ε ,

Modele zmiennej jakościowej można podzielić według wielu kryteriów. Pełną systematykę tych modeli, tabela 3, przedstawił Gruszczyński (2002).

Tabela 3. Systematyka modeli zmiennych jakościowych i ograniczonych.

Modele dwumianowe	Modele wielomianowe
liniowy model prawdopodobieństwa	Modele kategorii uporządkowanych
probitowy	logitowy
logitowy logarytmiczno - liniowy	probitowy
gompitowy	Modele kategorii nieuporządkowanych
komplementarny log-log	wielomianowy model logitowy
Burritowy	warunkowy model logitowy
ucięty LMP	zagnieżdżony model logitowy
krzywej Urbana	uogólniony model wartości ekstremalnych
Modele zmiennych ograniczonych	Modele licznikowe
regresja ucięta	regresja Poissonowska
modele tobitowe	model rozkładu ujemnego dwumianowego
dwugraniczny model tobitowy	model trwania
model doboru próby	model licznikowy ucięty
podwójny LMP	model płótkowy

Zródło: Gruszczyński (2002), s. 44

Oszacowanie prawdopodobieństwa realizacji wariantu (będącego jednocześnie wartością oczekiwaną zmiennej obcej):

$$P_i = F(b^0 + b^1 X_{i1} + \dots + b^k X_{ik})$$

$$i = 1, \dots, n$$

- $b^{\wedge}_0, b^{\wedge}_1, \dots, b^{\wedge}_k$ - oszacowania parametrów $\beta_0, \beta_1, \dots, \beta_k$,
- $x_{i1}, x_{i2}, \dots, x_{ik}$ –empiryczne wartości zmiennych objaśniających⁷.

2.2. Modele dwumianowe.

Dla celów pracy autor skupi się jedynie na modelach dwumianowych. Do najpopularniejszych modeli dwumianowych należą:

- Liniowy model prawdopodobieństwa
- Model probitowy
- Model logitowy.

Najprostszym i zarazem najczęściej stosowanym rodzajem zmiennych jakościowych są zmienne binarne (dwumianowe, dychotyczne), są to zmienne przyjmujące tylko dwie wartości. Modele zmiennych binarnych noszą nazwę modeli dwumianowych.

Przyjmijmy, że mamy do czynienia z binarną zmienną Y . Niech y_i , oznacza wartość zmiennej Y dla i -tego osobnika danej zbiorowości (lub i -tego wyboru), natomiast P_i , oznacza prawdopodobieństwo przyjmowania przez zmienną y_i , wartości 1.

W modelach dwumianowych zakłada się, że P_i , jest funkcją wektora wartości zmiennych egzogenicznych x_i oraz wektora parametrów β :

$$P_i = P(y_i = 1) = F(x_i^T \beta), \quad (1.1)$$

gdzie x_i , oraz β są kolumnowymi wektorami $(k+1)$ -elementowymi; kombinacja liniowa $x_i^T \beta$ jest wskaźnikiem określającym danego osobnika, natomiast F jest funkcją rosnącą tego wskaźnika. Typ funkcji F określa rodzaj modelu.

Podstawowe cele, jakie stawia się przed modelem (1.1), to: specyfikacja zmiennych egzogenicznych, estymacja wektora β na podstawie danych o wartościach zmiennych y , oraz x_i , a także prognoza wartości P_i .

Liniowy model prawdopodobieństwa szacujemy za pomocą metody najmniejszych kwadratów postaci: $y_i = \alpha + \beta * x_i + u_i$, przy założeniu, że $E(u_i) = 0$.

Wartość teoretyczna z równania regresji jest szacunkiem prawdopodobieństwa, że zdarzenie wystąpi dla konkretnej wartości zmiennej x . Zmienna jakościowa, w tymże modelu ma dwa możliwe warianty opisane przy użyciu kodów „0” i „1”. Jest, zatem dwumianowa.

⁷ Gruszczyński M. [2009], *Ekonometria i badania operacyjne*, Wydawnictwo Naukowe PWN, s. 179-181

Niech p_i oznacza prawdopodobieństwo zdarzenia $Y_i=1$. Wtedy $1-p_i$ jest prawdopodobieństwem zdarzenia $Y_i=0$. Wartość oczekiwana zmiennej Y_i to :

$$E(Y_i) = 1 \cdot p_i + 0 \cdot (1-p_i) = p_i,$$

Z kolei zakładając, że $E(\varepsilon_i) = 0$, czyli wartość oczekiwana Y_i równa się:

$$E(Y_i) = \alpha_0 + \alpha_1 X_i,$$

zatem:

$$p_i = \alpha_0 + \alpha_1 X_i,$$

W ten sposób $p_i = P(Y_i=1)$, gdzie P oznacza prawdopodobieństwo.

Zapisując LMP w ogólniejszej postaci z k zmiennymi objaśniającymi otrzymujemy:

$$Y_i = \alpha_0 + \alpha_1 X_{1i} + \dots + \alpha_k X_{ki} + \varepsilon_i \quad i=1,2,\dots,n.$$

Należy zaznaczyć, że parametr α_j ($j=1,\dots,k$) w tym modelu interpretuje się jako przyrost prawdopodobieństwa p_i związany z przyrostem X_j o jednostkę.

Modele probitowe i logitowe wywodzą się z tej samej grupy modeli prawdopodobieństwa. Niewielkie różnice w otrzymywanych wynikach sprawiły, że często są omawiane łącznie i zwraca się uwagę na różnice, jakie między nimi występują. Oba modele są do siebie bliźniaczo podobne⁸. Zasadnicza różnica między tymi modelami wyraża się w tym, że w modelu probitowym posługujemy się dystrybuantą rozkładu normalnego, bardzo podobną do dystrybuanty rozkładu logistycznego, którą posługujemy się w modelu logitowym.

W modelu logitowym funkcja, która wiąże prawdopodobieństwo p_i ze zmienną objaśniającą X_i jest wyrażana wzorem :

$$p_i = \frac{\exp(\alpha_0 + \alpha_1 X_i)}{1 + \exp(\alpha_0 + \alpha_1 X_i)},$$

gdzie $\exp(V) = e^V$. Model ten nosi też nazwę regresji logistycznej. Jego ogólniejsza postać przyjmuje, że p_i jest funkcją następującej liniowej kombinacji k zmiennych objaśniających⁹:

$$Z_i = \alpha_0 + \alpha_1 X_{1i} + \dots + \alpha_k X_{ki}$$

⁸ Gruszczyński M. [2009] *Ekonometria i badania ...*, op. cit., s. 179-181

⁹ Maddala G.S. [2006] *Ekonometria*, PWN, Warszawa, s. 234-235

czyli:

$$p_i = \frac{\exp(Z_i)}{1 + \exp(Z_i)}$$

Jeśli obliczymy:

$$1 - p_i = \frac{1}{1 + \exp(Z_i)}$$

następnie podzielimy p_i przez $1-p_i$:

$$\exp(Z_i) = \frac{p_i}{1 - p_i}$$

i obliczymy stąd $Z_i = \alpha_0 + \alpha_1 X_{1i} + \dots + \alpha_k X_{ki}$, to otrzymamy model 1.2 :

$$\ln \frac{p_i}{1 - p_i} = \alpha_0 + \alpha_1 X_{1i} + \dots + \alpha_k X_{ki}$$

Właściwą metodą estymacji modelu logitowego jest metoda największej wiarygodności (MNV), która wykorzystuje założenie o postaci rozkładu logistycznego, natomiast model probitowy wykorzystuje rozkład normalny podczas estymacji MNV.

W modelu logitowym ważną rolę spełniają efekty krańcowe. Pochodna prawdopodobieństwa p_i względem zmiennej objaśniającej X_{ji} w modelu logitowym jest następująca:

$$\frac{\partial p_i}{\partial X_{ji}} = \alpha_j p_i (1 - p_i) = \alpha_j \frac{\exp(\alpha_0 + \alpha_1 X_{1i} + \dots + \alpha_k X_{ki})}{[1 + \exp(\alpha_0 + \alpha_1 X_{1i} + \dots + \alpha_k X_{ki})]^2}$$

Znak oszacowania parametru stojącego przy zmiennej X_j w modelu logitowym i probitowym określa kierunek wpływu X_j na Y :

– dla dodatniego α_j wzrost X_j wiąże się ze wzrostem szans na to, że $Y = 1$; natomiast spadkowi X_j towarzyszy spadek szans na to, że $Y = 1$;

– dla ujemnego α_j wzrost X_j wiąże się ze spadkiem szans na to, że $Y = 1$; natomiast spadkowi X_j towarzyszy wzrost szans na to, że $Y = 1$.

Interpretacja parametru strukturalnego modelu logitowego czy probitowego jest podobna do interpretacji znanej dla modelu liniowego: znak parametru określa kierunek zależności między zmiennymi X_j oraz Y .

Miary dopasowania dla danych w przypadku stosowania modeli dwumianowych są od lat przedmiotem sporów teoretyków. Podstawowe pomysły teoretyków opierają się na różnych odpowiednikach współczynnika determinacji R kwadrat. Poniżej przedstawiono najbardziej popularne kryteria dobroci modelu.

Iloraz szans $p_i/(1-p_i)$ dobrze nadaje się do interpretacji oszacowanego modelu logitowego i probitowego. Można pokazać, że jeśli jedna ze zmiennych objaśniających, na przykład X_j wzrośnie o jednostkę (*ceteris paribus*), to iloraz szans zmieni się $\alpha \exp(\alpha_j)$ razy. W przypadku $\exp(\alpha_j) > 1$ mamy wzrost, a w przypadku $\exp(\alpha_j) < 1$ mamy spadek ilorazu szans.

Jeśli X_j jest zmienną zerojedynkową, to $\exp(\alpha_j)$ mówi ile razy wzrasta iloraz szans wartości $Y_i = 1$ dla kategorii „1” zmiennej X_j w porównaniu z tym samym ilorazem dla kategorii „0” zmiennej X_j ¹⁰.

W modelu logitowym i probitowym nie można stosować zwykłego współczynnika determinacji R-kwadrat (ze względu na nieliniowość). W zamian używa się pseudo-R-kwadrat McFaddena, który oblicza się według wzoru:

$$pseudo-R^2 = 1 - \frac{\ln L_{MP}}{\ln L_{MZ}},$$

gdzie $\ln L_{MP}$ jest logarytmem funkcji wiarygodności dla modelu pełnego, natomiast $\ln L_{MZ}$ – dla modelu zredukowanego do wyrazu wolnego. Pseudo-R-kwadrat może służyć do porównań pomiędzy logitowymi i probitowymi modelami niezagnieżdżonymi dla tej samej zmiennej.

Podana w wydruku wyników estymacji wartość statystyki testu ilorazu wiarygodności służy do testowania istotności całego modelu logitowego. Hipoteza zerowa mówi, że wszystkie parametry modelu – poza wyrazem wolnym – są równe zero. Statystyka testu zdefiniowana, jako:

$$chi\ kwadrat = 2(\ln L_{ur} - \ln L_{lr})$$

gdzie:

L_{ur} - wartość funkcji wiarygodności dla pełnego modelu,

L_{lr} – wartość funkcji wiarygodności dla modelu zawierającego jedynie wyraz wolny,

ma rozkład chi kwadrat z liczbą stopni swobody równą liczbie zmiennych objaśnianych modelu (bez wyrazu wolnego).

¹⁰ Maddala G.S. [2006] *Ekonometria...* op. cit., s. 216

Podane w wynikach estymacji wartości statystyki t dla parametrów służą – jak w klasycznym modelu liniowym – do testowania istotności każdej zmiennej oddzielnie.

Po oszacowaniu modelu logitowego można obliczyć wartości empiryczne zmiennej objaśnianej, czyli wartości logitów $\ln(p_i/(1-p_i))$ dla każdej z n obserwacji. Natomiast dla modelu probitowego tymi wartościami są probity, których będzie mowa na następnej stronie. Na tej podstawie wyznacza się wartości empiryczne p_i prawdopodobieństw \hat{p}_i . Wtedy, jak w przypadku LMP, można obliczyć prognozę *ex post* wartości Y_i dla każdej obserwacji. Są przy tym dwie zasady:

- zasada standardowa stosowana przy próbie zbilansowanej, to jest takiej gdzie liczba zer i jedynek dla zmiennej Y jest mniej więcej jednakowa; wówczas prognozujemy, że $Y=1$ dla $\hat{p}_i > 0,5$ oraz $Y=0$ dla $\hat{p}_i < 0,5$;
- zasada optymalnej wartości granicznej stosowana przy próbie niezbilansowanej, w której udział wartości $Y=1$ w próbie wynosi δ ; wówczas prognozujemy, że $Y=1$ dla $\hat{p}_i > \delta$ oraz $Y=0$ dla $\hat{p}_i < \delta$.

Trafność prognozy *ex post* wygodnie jest przedstawić za pomocą tablicy trafności, tabela 4.

Tabela 4. Tablica „trafności” modelu dwumianowego.

Empiryczne	Prognozowane		Razem
	Y=1	Y=0	
Y=1	$n11$	$n10$	$n1.$
Y=0	$n01$	$n00$	$n0.$
Razem	$n.1$	$n.0$	n

Źródło: Opracowanie własne na podstawie wydruku z programu Gretl.

Trafność interpretujemy następująco:

$$\text{Iloraz trafień} = \frac{n11 \cdot n00}{n01 \cdot n10}$$

$$\text{Trafność łączna} = \frac{n11 \cdot n00}{n}$$

$$\text{Trafność } Y=0 = \frac{n00}{n0.}$$

$$\text{Trafność } Y=1 = \frac{n11}{n1.}$$

Modele probitowe i logitowy mają wiele cech wspólnych, jednak można znaleźć takie charakterystyki modelu probitowego, które odróżniają go od modelu logitowego.

W modelu probitowym funkcja, która wiąże prawdopodobieństwo p_i z liniową kombinacją zmiennych objaśniających $Z_i = \alpha_0 + \alpha_1 X_{1i} + \dots + \alpha_k X_{ki}$ ma postać:

$$p_i = \int_{-\infty}^{Z_i} \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{t^2}{2}\right) dt$$

W tym modelu wartości prawdopodobieństwa p_i są wartościami dystrybuanty rozkładu normalnego $N(0, 1)$ w punktach Z_i . Wartości Z_i nazywa się probitami lub normitami. Są to wartości kombinacji liniowej (zbiorczego indeksu) zmiennych objaśniających dla określonego poziomu prawdopodobieństwa, przy założeniu, że kombinacja ta ma rozkład $N(0,1)$.

Pochodna prawdopodobieństwa p_i względem zmiennej objaśniającej X_{ji} w modelu logitowym jest następująca:

$$\frac{\partial p_i}{\partial X_{ji}} = \alpha_j \varphi(Z_i)$$

gdzie $\varphi(\cdot)$ jest funkcją gęstości standardowego rozkładu normalnego. Wartości, które zależą od poziomów zmiennych X podaje się zwykle dla średnich wartości tych zmiennych.

Pomiędzy parametrami α w modelu logitowym i probitowym zachodzi relacja:

$$\alpha_{logit} \approx \gamma \alpha_{probit}$$

gdzie $\gamma = 1,6 \div 1,7$, co pozwala łatwo przeliczać wyniki estymacji parametrów jednego modelu na drugi¹¹.

2.3. Modele dwumianowe w zastosowaniu do analizy finansowych szeregów czasowych.

2.3.1. Teoria prognozowania i analiza zdarzeń na rynkach kapitałowych.

Określenie *event study* oznacza w finansach badanie empiryczne, którego treścią jest określenie wpływu różnych decyzji bądź zdarzeń na wartość rynkową akcji spółek i ceny rynkowe ich długu. Chodzi o takie wydarzenia, jak splity, nowe emisje akcji i obligacji, umorzenia akcji, ogłoszenia o wielkości dywidendy.

¹¹ Gruszczyński M. [2009], *Ekonometria i badania ...*, op. cit., s. 184-195

Metodologia analizy wydarzeń została zaproponowana w przełomowych pracach Balia i Browna [1968] oraz Famy, Fishera, Jensena i Rolla [1969]. Różne warianty tego podejścia stosuje się do dziś.

W podstawowym modelu analizy wydarzeń zmienną endogeniczną jest na ogół stopa zwrotu, natomiast zmiennymi egzogenicznymi są kategorie charakteryzujące spółkę oraz obserwowane wydarzenie. W tym kontekście, modelowanie zmiennych jakościowych może być dwojakiego rodzaju. Po pierwsze można modelować nie stopy zwrotu, lecz kierunek ich zmian. Zmienna endogeniczną ma wówczas charakter jakościowy. Po drugie - czasem same wydarzenia mogą być traktowane, jako endogeniczne. Wtedy naturalną zmienną endogeniczną jest zmienna jakościowa.

Analiza wydarzeń oznacza w ekonometrii finansowej badanie wpływu na ceny akcji takich zdarzeń, jak splity, nowe emisje, umorzenia akcji, informacje o poziomie zysku czy dywidendy. Według Campbella, Lo i MacKinlaya [1997] typowe badanie wydarzeń składa się z następujących etapów:

1. Definicja wydarzenia oraz definicja okna wydarzenia. Jeśli na przykład zajmujemy się wartością predykcyjną doniesienia o poziomie zysku, to oknem tego zdarzenia jest dzień doniesienia, bądź dodatkowo dzień następny (gdy rozważamy notowania dzienne).
2. Ustalenie kryteriów wyboru spółek do próby podlegającej badaniu. Kryteria mogą dotyczyć obecności spółki na określonym rynku kapitałowym czy na określonej giełdzie papierów wartościowych.
3. Określenie normalnej i anormalnej (nadzwyczajnej) stopy zwrotu z akcji. Stopa normalna to oczekiwana stopa zwrotu w przypadku, gdyby zdarzenie nie miało miejsca. Stopa anormalna to różnica pomiędzy stopą faktycznie obserwowaną i stopą normalną. W celu ustalenia stopy normalnej korzysta się z wybranego modelu.
4. Estymacja modelu dla normalnej stopy zwrotu. W celu oszacowania wybranego modelu należy ustalić okno estymacji, to jest przedział, poprzedzający okno zdarzenia, na podstawie którego szacuje się model dla normalnej stopy zwrotu.
5. Procedura weryfikacji. Na tym etapie dokonuje się obliczenia wartości anormalnych stóp zwrotu oraz ustala się sposób weryfikacji hipotezy o wpływie zdarzenia (zdarzeń) na poziom tych stóp.

6. Wyniki empiryczne. Prezentuje się na ogół wyniki zagregowane, dotyczące reakcji całej wybranej grupy spółek na rozpatrywane zdarzenie.
7. Interpretacja i konkluzje. W sytuacji idealnej badanie zdarzeń prowadzi do wyjaśnienia mechanizmu wpływu zdarzeń na ceny papierów wartościowych.

Z każdym z wymienionych etapów wiąże się wiele problemów metodologicznych. Obszerne ich omówienie znaleźć można na przykład u Campbella, Lo i MacKinlaya [1997].

Problematyka prognozowania cen akcji spółek giełdowych należy do najatrakcyjniejszych we współczesnych finansach i ekonomii finansowej. Świadczy o tym różnorodność stosowanych podejść formalnych oraz literatura, szczególnie obfita w ostatnich latach. Z tych względów trudno o wyczerpujący przegląd tej literatury.

Jednym z nurtów badań empirycznych i teoretycznych w dziedzinie prognozowania kursów akcji jest analiza predykcyjnej wartości wyników finansowych ogłaszanych przez spółki. Jest to część analizy fundamentalnej, odnosząca się bezpośrednio do kondycji samych spółek. Inne fundamentalne dane, mogące mieć wpływ na notowania papierów wartościowych, to informacje o poziomie makrokategorii gospodarczych, o decyzjach dotyczących regulacji rynku, o ważnych wydarzeniach politycznych i ekonomicznych itd. Po kryzysie 1987 roku, którego nie można było powiązać z żadnymi tego rodzaju informacjami, spadło zaufanie do ich zdolności predykcyjnej. Cutler, Poterba i Summers [1989] wykazali, że informacje makroekonomiczne oraz wiadomości o światowych wydarzeniach polityczno-ekonomicznych mogą wyjaśniać jedynie około 30% zmienności indeksów cen akcji w USA.

Reakcja rynku na wyniki finansowe pojedynczych spółek zależy od tego, czy są one lepsze czy gorsze od wyników oczekiwanych przez inwestorów. Na rynku efektywnym reakcja taka jest natychmiastowa. Jeśli informacja zawarta w raporcie finansowym jest niespodzianką, wówczas niespodzianka pozytywna skutkuje wzrostem cen akcji, a negatywna - spadkiem. Miarą oczekiwań inwestorów mogą być:

- wynik sprzed roku; jeśli wynik obecny jest lepszy, to niespodzianka jest, pozytywna, jeśli gorszy - negatywna;
- szacunki analityków; są one traktowane, jako substytut wyników oczekiwanych. Badania rozwiniętych rynków kapitałowych potwierdzają istnienie zależności pomiędzy wynikami osiąganymi przez spółki a notowaniami akcji w okresie bezpośrednio następującym po

ogłoszeniu wyników. Damodaran [1996] omawia wyniki analiz rynku amerykańskiego, w których wykazuje się, że:

- przyrost (spadek) wartości zysku bądź dywidendy na akcję wiąże się ze wzrostem (spadkiem) stopy zwrotu z akcji;
- w wielu przypadkach rynek reaguje na wyniki finansowe już na sesji poprzedzającej ogłoszenie wyników; może to być dowód na istnienie insider trading;
- trend ceny akcji w dłuższym okresie po ogłoszeniu wyników stabilizuje się, przy czym jest to trend rosnący po wynikach dobrych i malejący - po złych.

Rezultaty podobnych badań opisują także Sharpe i Alexander [1990]. Dla grupy 2053 spółek w okresie 1974-1981 w USA Foster, Olsen i Shevlin [1984] zbadali związek pomiędzy nieoczekiwanym poziomem zysku oraz anormalną stopą zwrotu z akcji (*abnormal return*). W badanej próbie korelacja między tymi kategoriami okazała się wysoce dodatnia, przy czym rozważano jedynie wyniki kwartalne i ich wpływ na cenę akcji w przedziale [-1, +60] sesji od dnia ogłoszenia. Kwestiami dyskusyjnymi w tego typu badaniach - poza zakresem próby i długością szeregu czasowego - są sposoby pomiaru kategorii będących przedmiotem analizy. Chodzi o ustalenie, jaki poziom zysku przedstawiony w ogłoszeniu o wynikach można uznać za nieoczekiwany (niespodzianka pozytywna lub negatywna) i jak go mierzyć oraz jaka stopa zwrotu z akcji jest stopą „normalną”¹².

2.3.2. Modele mikroekonometryczne w analizach giełdowych szeregów czasowych.

Jeśli chodzi o badania na rynku polskim to pokaźny zasługę wkład ma praca Gruszczyńskiego (2002), w której autor badał zachowanie się akcji spółek w dniu i dzień po ogłoszeniu wyników miesięcznych dla spółek notowanych na giełdzie papierów wartościowych. Gruszczyński badał wpływ wyników finansowych spółek publicznych w Polsce na poziom ich notowań na giełdzie. Jego analiza wykazała, że nie potwierdza się przydatność informacji o miesięcznych wynikach finansowych spółek publicznych w Polsce do prognozowania operacyjnego. Na podstawie informacji o wyniku nie można było podjąć krótkoterminowej decyzji inwestycyjnej.

Kolejnymi badaniami na temat analizy zdarzeń były prace Batóg i Wawrzyniak (2004), (2005), (2007), które traktowały o możliwości wykorzystania modeli dwumianowych do formułowania i przewidywania łącznych diagnoz dla spółek notowanych na polskiej giełdzie.

¹² Gruszczyński M. [2002], *Modele i prognozy zmiennych jakościowych...* s. 201-205

Autorki wykazały, że łączne diagnozy mogą być podstawą do porównań między sektorowych. O wykorzystaniu modeli binarnych na rynku opcji traktuje praca Burzały (2009). Autorka podjęła próbę wykorzystania w tym celu prawdopodobieństwa realizacji europejskiej opcji kupna uzyskane z dwumianowego modelu wyboru dyskretnego. Przeprowadzona analiza wskazuje, że najlepsze wyniki można uzyskać z dwumianowych modeli logitowych przy wykorzystaniu informacji o kursie opcji na rynku wtórnym.

Modele dwumianowe również są powszechnie używane do analizy giełdowych szeregów czasowych poza naszym krajem. Na świecie powstało wiele prac dotyczących tych zagadnień. Autor w części pracy dotyczącej badań empirycznych przeanalizuje dotychczasowe dokonania z tej dziedziny.

Rozdział III

Wykorzystanie modelu probitowego w procesie alokacji aktywów między indeksy Wig20 i sWig80

3.1. Charakterystyka opisowa indeksów Wig20 i sWig80.

Wig20 to indeks giełdowy 20 największych spółek akcyjnych notowanych na Warszawskiej Giełdzie Papierów Wartościowych. Wyjściową datą dla indeksu jest 16 kwietnia 1994, zaś wartością bazową 1000 punktów. Jest to indeks typu cenowego. W ramach Wig20 nie może być notowanych więcej niż 5 spółek z jednego sektora; nie są w nim notowane fundusze inwestycyjne.

Listę spółek wchodzących w skład indeksu WIG20 ustalono na podstawie średniej ważonej dwóch kryteriów:


- wielkości obrotu giełdowego akcji spółki w relacji do łącznych obrotów wszystkich spółek wchodzących w skład indeksu w okresie trzech miesięcy,
- wartości rynkowej spółki w relacji do kapitalizacji spółek wchodzących w skład indeksu w okresie miesiąca.

Indeks giełdowy małych spółek notowanych na warszawskiej Giełdzie Papierów Wartościowych - sWig80 zastąpił po sesji w dniu 16 marca 2007 indeks WIRR. W jego skład wchodzi stała liczba 80 spółek. Spółki do indeksu sWIG80 wybierane są na podstawie tego samego rankingu, co do WIG20 i mWIG40 jako 80 kolejnych, które nie weszły do WIG20 i mWIG40. Pomimo, że od 1 stycznia 1995 roku do 16 marca 2007 roku na giełdzie notowany był indeks WIRR, autor dla celów badawczych będzie ten indeks utożsamiał z indeksem sWig80. Dodatkowo będziemy się posługiwać cały czas nazwą sWig80, zamiast WIRR.

Wykres 1 przedstawia ujęcie wspólne indeksu Wig20 i sWig80. Można zauważyć, iż do roku 2004 indeksy były silnie skorelowane ze sobą. Natomiast od 2004 do połowy 2007 roku można obserwować dominację sWig80. Był to okres boomu na giełdzie. Inwestycje w spółki małe, bardziej ryzykowne, mające większy potencjał wzrostu były wówczas bardzo popularną inwestycją kapitału wśród inwestorów. Jednak po tym okresie nastąpił początek dekonjunktury na rynku papierów udziałowych i zauważalny odwrót od spółek małych.

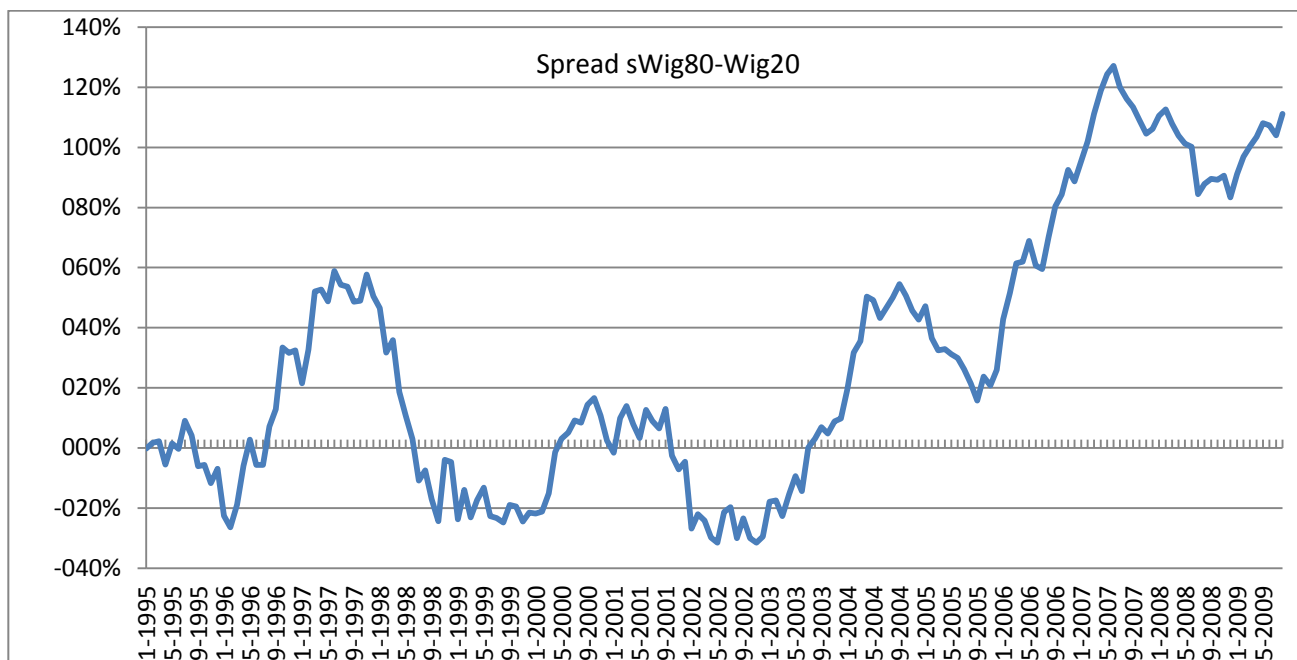
Jeszcze lepiej te różnice w stopach zwrotu obrazuje wykres 2, która przedstawia procentowy spread skumulowany między sWig80, a Wig20.

Wykres 1. Stopy zwrotu skumulowane w ujęciu procentowym.



Źródło: Opracowanie własne.

Wykres 2. Spread skumulowany w ujęciu procentowym: sWig80 – Wig20.



Źródło: Opracowanie własne.

Powyżej widoczne odchylenia w stopach zwrotu między opisywanymi indeksami są na tyle istotne, że wydaje się zasadnym przeprowadzenie analizy przyczyn powstawania tych odchyżeń jak i opracowanie strategii inwestycyjnej, która mogłaby pokonać strategię oparte na zasadzie „kup i trzymaj”

3.2. Analiza dotychczasowej literatury.

Analizując literaturę przedmiotu można znaleźć wiele opracowań wybitnych naukowców, którzy dowodzą, iż inwestycje w spółki małe w średnim i długim horyzoncie czasowym dają lepszą relację zysku do ryzyka. Tego typu dowody można znaleźć w pracach Capual, Rowley i Sharpe (1993), Arshanapalli, Coggin i Doukas (1998), Fama and French (1998), Bauman (1998) and Reinganum (1999). Jednak w praktyce tak konsekwentna strategia może nie przynieść wymiernych korzyści. Dzieje się to z tego powodu, że w długim okresie czasu spółki mogą ewaluować; te mniejsze mogą stać się większymi, z drugiej strony większe mogą stać się mniejszymi. W tym celu w wielu pracach poddano badaniom strategię opartą na aktywnej, rotacyjnej alokacji kapitału między spółki małe i spółki duże. Na wykresie 2, można zauważyć jak duże ruchy występują na spreadzie między sWig80, a Wig20. Naturalne pytanie się więc nasuwa, jak te odchylenie wykorzystać i zająć w odpowiednim czasie odpowiednią pozycję na spreadzie. Badania Sharpe'a (1993) i Jeffrey (1984) dowodzą, że można znaleźć odpowiednie momenty na rynku aby w pełni wykorzystać odchylenia na spreadzie. W swojej pracy Bauer i Dalhquist (2001) pokazują, że strategia trzymania spółek dużych w portfelu nieznacznie pokonuje strategię rotacyjną między dużymi, a małymi spółkami. Można znaleźć jednak wiele badań, które potwierdzają, że umiejętnie skonstruowane modele taktycznej alokacji aktywów są w stanie pokonać strategię pasywną. Na przykład Arshanapalli, Coggin i Doukas (1998) w swojej pracy wskazują, że odchylenia na spreadzie między różnymi indeksami nie mogą być wyjaśniane jedynie poprzez przeszłe zachowania szeregów czasowych, lecz powinny być prognozowane z pomocą zmiennych makroekonomicznych. Kao i Shumker (1999) dowodzą, iż użycie krzywej dochodowości, rentowności obligacji czy prognozowanej zmiany produktu narodowego brutto jest skutecznym prognostykiem zachowań spreadu. Podobnie Anderson (1997) jest zdania, że zależności wykrywane w zmianach krzywej dochodowości mogą mieć wpływ na odchylenia między indeksem dużych i małych spółek.

Wyżej zaprezentowane metody bazują na wychwytywaniu odchyżeń na spreadzie z pomocą modeli opierających się na metodach ilościowych. Z drugiej jednak strony istnieje grupa badaczy,

którzy uważają, że metodami prostszymi i skuteczniejszymi są strategie momentum. Strategie tego typu bazują w większości na autokorelacji stóp zwrotu. Analiza wyników zaprezentowanych w pracach Lo i McKinley (1990) i Jegadeesh i Titman (1993) dowodzi, iż strategie tego typu należy umiejętnie skonstruować zarówno pod względem okresu trwania inwestycji, jak i pod względem odpowiedniego momentu zawarcia transakcji. Autor w tej pracy będzie starał się porównać obie metody wykorzystywane w zaprezentowanym przeglądzie literatury. Dodatkowo przedstawi własne metody badawcze.

Wyselekcjonowanie zbioru zmiennych objaśniających było wynikiem przemyśleń autora dotyczących dotychczasowych analiz prac naukowych z tejże tematyki oraz własnych analiz. Autor starał się w jak największym stopniu rozbudować zbiór zmiennych objaśniających, gdyż z jego wcześniejszych badań, (Arendarski, 2009) wynikało, że im więcej istotnych zmiennych w modelu, tym lepsze wyniki predykcji. Aby z dużego zbioru zmiennych objaśniających wybrać te istotne, autor zastosuje testy statystyczne.

3.3. Cel pracy, hipotezy badawcze

W rozdziale tym dokonano badania w celu odpowiedzi na pytanie czy krótkoterminowe różnice w zmianach stóp zwrotu między indeksami dużych i małych spółek mogą być lepiej wyjaśniane¹³ przez następujące metody:

- ✓ model probitowy
- ✓ strategie momentum
- ✓ równo ważoną strategię pasywną¹⁴

Strategia momentum polega na wyborze do portfela indeksu (kupienie indeksu), który w poprzednim miesiącu uzyskał niższą stopę zwrotu. W ten sposób w każdym z miesięcy portfel będzie się składał albo w 100% z indeksu Wig20 albo z indeksu sWig80.

Autor w poszukiwaniu metod, które „lepiej wyjaśniają” odchylenia na spreadzie Wig20 – sWig80, szuka takich modeli, za pomocą, których portfel inwestycyjny posiada najwyższą wartość wskaźnika stopa zwrotu / odchylenie standardowe.

Dodatkowo autor odpowie na pytania:

¹³ Autor przyjął założenie, że „lepiej wyjaśnia” metoda, za pomocą której można uzyskać wyższą relację stopa zwrotu / odchylenie standardowe

¹⁴ Strategia pasywna polega na skonstruowaniu portfela składającego się w 50% z indeksu Wig20 i w 50% z indeksu sWig80. Skład portfela jest stały przez cały okres.

- Które z kryteriów dobroci modeli probitowych najlepiej wyjaśnia odchylenia na spreadzie Wig20 – sWig80.

Jako kryteria dobroci modelu probitowego autor wyróżnił:

- Test ilorazu wiarygodności,
- Iloraz szans wyznaczony na podstawie tabeli trafności klasyfikacji przypadków,
- Kryterium Akaike’a,
- Absolutny błąd prognozy,
- Czy stosowanie dywersyfikacji¹⁵ przy użyciu skorelowanych ze sobą instrumentów polepsza relację stopa zwrotu / odchylenie standardowe.

3.4. Metodologia i wyniki badań

Badanie obejmowało okres od początku 1995 roku do maja 2009 roku. Autor wykorzystał miesięczne stopy zwrotu.

Zmiany danej zmiennej były liczone według wzoru:

$$\text{Zmiana } X = \ln(X)_t - \ln(X)_{t-1}$$

Spread dla zmiennej będącej różnicą zmiennnej 1 i zmiennej 2 był liczony według wzoru:

$$\text{Spread } (X1,2) = [\ln(X1)_t - \ln(X1)_{t-1}] - [\ln(X2)_t - \ln(X2)_{t-1}]$$

Dokonano wyboru zmiennych objaśniających opierając się na badaniach wspomnianych we wprowadzeniu.

Wyselekcjonowane zmienne objaśniające poddano testowi Simsa na zbadanie istnienia związków przyczynowych między zmienną objaśnianą a opóźnionymi zmiennymi objaśniającymi.

Test Simsa jest jednym z testów przyczynowości w sensie Grangera. Główne założenie tego testu mówi, iż jeżeli istnieje równanie regresji Y_t w zależności od przeszłych i przyszłych wartości X_t , to w przypadku, gdy współczynniki stojące przy przyszłych wartościach procesu X_t są nieistotnie różne od zera mówimy, że Y_t nie jest przyczyną X_t w sensie Grangera. Proces X_t jest zatem egzogeniczny w stosunku do Y_t .¹⁶

¹⁵ Jako dywersyfikację autor rozumie lokowanie kapitału w oba instrumenty: Wig20 oraz sWig80. W przeciwnym wypadku kapitał będzie lokowany albo w Wig20 albo w sWig80.

¹⁶ Osińska M. [2008] Ekonometryczna analiza zależności przyczynowych, Wydawnictwo Naukowe Uniwersytetu Mikołaja Kopernika, Toruń, s. 79-81

Test Simsa przeprowadzono klasyczną metodą najmniejszych kwadratów. Nie występuje tu bowiem autokorelacja reszt. Zmienne objaśniające zachowują stacjonarność. Przeprowadzono badanie 3 kolejnych opóźnień zmiennych X względem zmiennej Y. Autor wybrał 3 opóźnienia zmiennych objaśniających kierując się analizą dotychczasowej literatury. Przyjęto H_0 mówiącą o tym, że współczynniki stojące przy przyszłych wartościach procesu X_t są nieistotnie różne od zera. Hipotezę zerową weryfikuje się za pomocą testu T-Studenta na istotność parametrów w równaniu regresji. Do odrzucenia H_0 autor przyjął zasadę aby wartość p była mniejsza od 0,10.

Tabela 5 przedstawia wybór zmiennych objaśniających niezależnych oraz wartości p dla poszczególnych zmiennych i ich opóźnień. Tabela 4 przedstawiała analogiczne wartości dla zmiennych objaśniających typu spread. W obu tabelach wyróżniono zmienne o określonym opóźnieniu, które okazały się istotnie wpływać na przyszłe wartości spreadu między Wig20 i sWig80. Zostały one zakwalifikowane do kolejnego etapu badania.

Tabela 5. Wyniki testu Sims'a dla zmiennych niezależnych.

		Wartość p dla danego opóźnienia		
Zmienne niezależne	Symbol	1	2	3
Zmiana rentowności 10-letnich obligacji skarbu USA	OblUs10	0,4621	0,1065	0,183
Zmiana rentowności 30-letnich obligacji skarbu USA	OblUs30	0,4146	0,2576	0,2886
Zmiana cen długoterminowych obligacji skarbu Niemiec - Bund	Bund	0,9995	0,8559	0,2951
Zmiana cen średnioterminowych obligacji skarbu Niemiec - Bobl	Bobl	0,9541	0,8735	0,3783
Kwartalna wartość Produktu Krajowego Brutto USA	PkbUs	0,343	0,221	0,432
Zmiana agregatu monetarnego M1 w USA	M1Us	0,8742	0,7642	0,7006
Zmiana agregatu monetarnego M2 w USA	M2Us	0,4116	0,4893	0,5111
Zmiana agregatu monetarnego M1 w strefie Euro	M1Eur	0,5371	0,3204	0,2168
Zmiana agregatu monetarnego M2 w strefie Euro	M2Eur	0,9894	0,418	0,4792
Zmiana produkcji przemysłowej USA	PPrzUS	0,9135	0,0524	0,8391
Stopa inflacji w USA	InfUs	0,1635	0,977	0,9102
Zmiana cen kontraktów na pallad	Pallad	0,381	0,1489	0,426
Zmiana cen kontraktów na złoto	Złoto	0,8679	0,1179	0,9685
Zmiana cen kontraktów na miedź	Miedź	0,033	0,9542	0,7717
Zmiana cen kontraktów na żywe bydło	Żbydło	0,5286	0,9057	0,8197

c.d. Tabela 5.

Zmiana cen kontraktów na młode bydło	Mbydło	0,574	0,719	0,4774
Zmiana cen kontraktów na indeks S&P500	SP500	0,1198	0,3436	0,0326
Zmiana cen kontraktów na indeks S&P100	SP100	0,2341	0,2976	0,327
Zmiana cen kontraktów na indeks S&P400 Średniej Kapitalizacji	SP400	0,0442	0,0742	0,0253
Zmiana cen kontraktów na ryż	Ryż	0,1738	0,4112	0,5498
Zmiana cen kontraktów na soję	Soja	0,0936	0,9046	0,6879
Zmiana cen kontraktów na kakao	Kakao	0,2738	0,1675	0,7573
Zmiana cen kontraktów na bawełnę	Bawełna	0,8948	0,741	0,4968
Zmiana cen kontraktów na ropę brent	Brent	0,9865	0,2789	0,8392
Zmiana kursu Dolar/Złoty	USDpln	0,5002	0,3377	0,3679
Zmiana kursu Euro/Złoty	EURpln	0,2145	0,3639	0,1865
Zmiana kursu Dolar/Jen	USDjpy	0,0026	0,8491	0,1179
Zmiana kursu Euro/Dolar	EURusd	0,3893	0,135	0,7912
Zmiana indeksu ISM - Purchasing Managers Index	ISM	0,0076	0,0412	0,1257

Zródło: Opracowanie własne.

Tabela 6 . Wyniki testu Sims'a dla zmiennych typu spread.

		Wartość p dla danego opóźnienia		
Zmienne typu spread	Kod	1	2	3
OblUs10 - Bund	OblUs10_Bund	0,5292	0,1776	0,181
OblUs30 - Złoto	OblUs30_Złoto	0,61600	0,07270	0,41820
OblUs30 - OblUs10	OblUs30_OblUs10	0,5395	0,5929	0,748
OblUs10 - PkbUs	OblUs10_PkbUs	0,5042	0,2033	0,2648
M1Us - M1Eur	M1Us_M1Eur	0,6794	0,5259	0,1882
M1Us - M2Us	M1Us_M2Us	0,431	0,839	0,946
M1Us - PPrzUs	M1Us_PPrzUs	0,8655	0,391	0,8759
PPrzUs - InfUs	PPrzUs_InfUs	0,5053	0,0724	0,8041
Bund - Bobl	Bund_Bobl	0,9374	0,8751	0,3387

c.d. Tabela 6.				
Złoto - SP100	Złoto_SP100	0,0724	0,91	0,93
SP100 - SP400	SP100_SP400	0,4266	0,5581	0,0314
SP500 - SP400	SP500_SP400	0,9917	0,0373	0,3957
Złoto - Brent	Złoto_Brent	0,9261	0,7108	0,853
Brent - SP500	Brent_SP500	0,2884	0,5361	0,445
USDpln - SP500	USDpln_SP500	0,2229	0,2486	0,0542
EURpln - Brent	EURpln_Brent	0,5093	0,1613	0,3891
USDpln - Brent	USDpln_Brent	0,8162	0,2104	0,64
USDpln - EURpln	USDpln_EURpln	0,3945	0,7425	0,4287
ISM - SP500	ISM_SP500	0,0003	0,5404	0,0069
ISM - USDpln	ISM_USDpln	0,0197	0,0379	0,6335

Źródło: Opracowanie własne.

Zmienne, których wartości podawane są z opóźnieniem (np. inflacja, zmiana produkcji przemysłowej) podane są jako opóźnione o 1 okres w stosunku do zmiennych rynkowych, wartości których są podawane na bieżąco. I tak np. zmienna typu spread: ISM – USDpln, składa się z wartości ISM w czasie t-2 oraz z wartości USDpln w czasie t-1 w stosunku do spreadu między Wig20, a sWig80.

Zmiana każdej zmiennej jest wyrażona w taki sposób, że $X_t = \ln(X_t) - \ln(X_{t-1})$. Następnie wyselekcjonowane zmienne na podstawie testu Simsa otrzymały nazwy zgodnie z opóźnieniem, które reprezentują według wzoru:

$$\text{Nowa zmienna} = X_t,$$

gdzie:

X – nazwa zmiennej

t – liczba opóźnień

Kolejnym krokiem było stworzenie rankingu ze wszystkich istotnych zmiennych na podstawie kryterium, którym została wartość p. Im niższa wartość p, tym zmienna wyżej w rankingu. Tabela 7 przedstawia ranking zmiennych.

Następnie przystąpiono do estymacji modeli ekonometrycznych prognozujących zmianę spreadu między Wig20, a sWig80. Do tego celu użyto modelu probitowego.

Tabela 7. Ranking testu Simsa według wartości p w ujęciu procentowym.

1	ISM_SP500_1	0,03%
2	USDjpy_1	0,26%
3	ISM_SP500_3	0,69%
4	ISM_1	0,76%
5	ISM_USDpln_1	1,97%
6	SP400_3	2,53%
7	SP100_SP400_3	3,14%
8	SP500_3	3,26%
9	Miedź_1	3,30%
10	SP500_SP400_2	3,73%
11	ISM_USDpln_2	3,79%
12	d_ISM_2	4,12%
13	SP400_1	4,42%
14	PPrzUS_2	5,24%
15	Usdpln_SP500_3	5,42%
16	PrPrzUs_Inf_2	7,24%
17	Złoto_SP100_1	7,24%
18	OblUs30_Złoto_2	7,27%
19	SP400_2	7,42%
20	Soja_1	9,36%

Źródło: Opracowanie własne

Analizowany model będzie miał postać: $P(Y_{t+1} = 1|X) = P(y=1|X_t)$

gdzie,

X – zmienne objaśniające

$Y_{t+1} = 1$, jeśli różnica w ujęciu procentowym między Wig20, a sWig80 będzie dodatnia w okresie jedni miesiąca naprzód względem zmiennych objaśniających, w przeciwnym wypadku $Y_{t+1} = 0$.

Do oszacowania poprawności estymowanych modeli użyto 2 kryteriów opisanych w rozdziale 2.2:

- a) Test ilorazu wiarygodności, służący do weryfikacji hipotezy zerowej mówiącej o tym, że wszystkie parametry modelu, poza wyrazem wolnym, są równe zero,
- b) Iloraz szans wyznaczony na podstawie tabeli trafności klasyfikacji przypadków.

Dodatkowo wybrano 2 kryteria, które nie są opisywane w literaturze jako kryteria dobroci modelu. Są to:

- c) Kryterium Akaike'a, obliczane według wzoru :

$$AIC = -2 \ln L + 2k; L = \max \{L(\theta_i, D) \geq 0;$$

gdzie:

$L(\theta_i, D)$ - funkcja wiarygodności dla parametrów modelu θ_i i danych empirycznych D ,

k - liczba składowych wektora parametrów θ modelu (liczba parametrów modelu).

We wzorze na AIC występują dwa wyrażenia. Pełnią one następujące funkcje:

L - określa stopień dopasowania modelu (zgodność modelu z danymi empirycznymi),

$2k$ - określa stopień złożoności (skomplikowalności) modelu.

Uogólniając; kryterium Akaike'a służy z jednej strony do poszukiwania modelu o najmniejszej złożoności, a z drugiej strony o najlepszym dopasowaniu.

- d) Absolutny błąd prognozy, obliczany według wzoru:

$$Q_t = y_t - y_t^*$$

gdzie:

y_t - rzeczywista wartość zmiennej prognozowanej Y w momencie/okresie t ,

y_t^* - prognoza zmiennej Y na moment/okres t .

Absolutny błąd prognozy przyjmuje zatem wartości nieujemne i jest wykorzystywany do oceny rzędu odchyleń zmiennej prognozowanej od prognozy. Wykorzystywany jest jako kryterium dobroci modelu w modelach liniowych.

Powyższy wybór miar dobroci modelu nie był przypadkowy. Autor wybierając test ilorazu wiarygodności i iloraz szans kierował się wskazaniem teoretyków, badaczy, którzy we wcześniejszych badaniach wskazali na wysoką efektywność tych miar. Natomiast dwie pozostałe miary, tj. kryterium Akaike'a oraz absolutny błąd prognozy zostały wybrane przez autora w ramach eksperymentu.

Interpretacja wartości parametrów:

Test ilorazu wiarygodności – wartość istotności p mniejsza od 0,05 oznacza, że co najmniej jedna zmienna objaśniająca w modelu jest istotna statystycznie. Naturalną konsekwencją tego będzie

szukanie modeli efektywnych o jak najmniejszej wartości istotności p.

Iloraz szans – tak zwany R kwadrat zliczeniowy – im więcej będzie trafnych prognoz, tym model będzie bardziej efektywny.

Kryterium Akaike'a - dla modeli określonych za pomocą parametrów istotnych funkcja AIC jest malejąca, natomiast dla modeli zawierających oprócz parametrów istotnych parametry dodatkowe (nieistotne) funkcja AIC jest rosnąca. Im mniejsza wartość tej miary tym model bardziej efektywny.

Absolutny błąd prognozy (bezwzględny błąd prognozy) – im mniejsza wartość tym lepiej dopasowany model. Im mniejsza wartość tej miary tym model bardziej efektywny.

Głównym celem estymacji modeli było znalezienie po jednym modelu, który by optymalizował kryteria opisane powyżej.

Następnie dokonano estymacji modeli w oparciu o dwie metody krokowe konstrukcji modelu probitowego:

a) Algorytm regresji krokowej postępującej.

Do modelu włączono zmienne opisane w tabeli 7. Przyjęto, że zmienna zajmująca najwyższą pozycję to zmienna X1, zmienna z drugiej pozycji to zmienna X2, w ten sposób, że zmienna z pozycji i-tej = Xi. Rozpoczęto estymację od modelu postaci:

$$Y = \beta_1 + \beta_2 X_1$$

Po czym dokładano jedną zmienną z pozycji o jeden stopień niżej, w taki sposób że kolejny model miał postać:

$$Y = \beta_1 + \beta_2 X_1 + \beta_3 X_2$$

Uogólniając kolejny model wyznaczano ze wzoru:

$$Y_j = \beta_1 + \beta_2 X_i + \beta_{i+1} X_{i+1}$$

gdzie:

i - pozycją w rankingu z tabeli 7,

j – numer modelu,

W ten sposób stworzono 20 modeli. Dodatkowo w każdym modelu usuwano najmniej istotną zmienną i estymowano go ponownie; implikowało to powstanie kolejnych 18 modeli.

b) Algorytm regresji krokowej wstecznej.

Polega on na skonstruowaniu modelu zawierającego wszystkie potencjalne zmienne objaśniające, a następnie na stopniowym eliminowaniu zmiennych tak, aby otrzymać model z najwyższą wartością parametrów (które są kryterium wyboru modelu, przy zachowaniu istotności parametrów).

Całe badanie obejmowało okres od 1995 do 2009 roku, z podziałem na okres treningowy od 1995 do 2001 roku, składający się z 72 miesięcznych obserwacji oraz okres treningowy od 2002 do 2009 roku składający się z 89 obserwacji. Wykorzystując wyselekcjonowany zbiór zmiennych stworzono prognozy na kolejne 12 miesięcy. Wykorzystując wyestymowane na zbiorze treningowym modele dokonano pierwszej prognozy w styczniu 2002 roku na kolejne 12 okresów. Następnie dodano te 12 okresów do zbioru treningowego i mając już 101 obserwacji dokonano prognozy w styczniu 2003 roku na kolejne 12 okresów. Całą procedurę kontynuowano do 2009 roku.

Powyższa metoda znalazła uznanie w oczach wielu badaczy, między innymi Gokani i Todorovic (2006) wykorzystali podobną metodą w celu zbadania właściwości spreadu między dużymi i małymi spółkami oraz między „wartościowymi” i „wzrostowymi” spółkami. Autor postanowił trzymać się tej konwencji.

Ostatecznie stworzono 39 modeli. Tabela 8 i 9 przedstawia modele wraz z wartościami kryteriów, które były brane pod uwagę przy selekcji modeli. Tabele 8 należy czytać w następujący sposób; w modelu 1 zmienną objaśniającą jest zmienna 1 (tabela 7), w modelu 2 zmiennymi objaśniającymi są zmienna 1 i 2, w modelu 3 zmiennymi objaśniającymi są zmienne 1, 2 i 3, w końcu model 20 będzie zawierał w sobie wszystkie zmienne objaśniające. Uogólniając można przyjąć, że:

$$\text{Model } N = \{a_1, a_2, \dots, a_t\},$$

gdzie:

N – numer modelu

t – numer zmiennej

a – zmienna

W tabeli 9 umieszczono modele, powstałe po usunięciu najmniej istotnej zmiennej z każdego modelu. Tabele 9 należy czytać w następujący sposób:

$$\{\text{Model } N_a \in \text{Model } N \Delta \text{Model } N_a \notin Z\},$$

gdzie:

Z – zmienna najmniej istotna

Parametry ostatniego modelu otrzymanego algorytmem regresji krokowej wstecznej w 39 podejściu. Tabela 10 prezentuje główne parametry modelu.

Tabela 8. Poszczególne modele probitowe.

Model/Numer zmiennej	Zmienne	Liczba przypadków poprawnej predykcji	Test ilorazu wiarygodności [wartość p]	Kryt. inform. Akaike'a	Średni błąd absolutny
1	ISM_SP500_1	54,90%	0,0086	110,7211	0,4601
2	USDjpy_1	65,90%	0,0076	109,8806	0,44407
3	ISM_SP500_3	61,00%	0,0047	108,672	0,42961
4	ISM_1	67,10%	0,0009	104,8316	0,39845
5	ISM_USDpln_1	69,50%	0,0004	103,1714	0,37924
6	SP400_3	69,50%	0,001	105,1129	0,37889
7	SP100_SP400_3	68,30%	0,0002	101,18	0,35296
8	SP500_3	68,30%	0,0002	101,7007	0,34652
9	Miedz_1	70,70%	0,0002	101,8379	0,33819
10	SP500_SP400_2	72,00%	0,0004	103,7662	0,33795
11	ISM_USDpln_2	69,50%	0,0005	104,6234	0,33358
12	ISM_2	76,80%	0,0006	105,4234	0,32696
13	SP400_1	76,80%	0,0009	106,7519	0,32265
14	PPrzUS_2	75,60%	0,0011	107,7824	0,3183
15	Usdpln_SP500_3	75,60%	0,0015	109,0837	0,31402
16	PrPrzUs_Inf_2	76,80%	0,0024	111,0044	0,31357
17	Zloto_SP100_1	74,40%	0,0032	112,4256	0,31184
18	ObIUs30_Zloto_2	72,00%	0,0031	112,8548	0,30436
19	SP400_2	73,20%	0,0046	114,771	0,30414
20	Soja_1	0,72	0,0044	115,1717	0,29773

Źródło: Opracowanie własne

Tabela 9. Poszczególne modele probitowe, z których usunięto najmniej istotną zmienną.

Model	Najmniej istotna zmienna	Liczba przypadków poprawnej predykcji	Test ilorazu wiarygodności [wartość p]	Kryt. inform. Akaike'a	Średni błąd absolutny
3a	USDJpy	59,80%	0,0035	108,2908	0,43767
4a	ISM_SP500	67,10%	0,0003	102,9338	0,39875
5a	d_ISM_1	69,50%	0,0002	101,271	0,37978
6a	SP400_3	69,50%	0,0004	103,1714	0,37924
7a	ISM_SP500_1	68,30%	0,0001	99,40718	0,35351
8a	ISM_SP500_1	72,00%	0,0001	100,0496	0,34736
9a	ISM_SP500_1	73,20%	0,0001	99,93159	0,33806
10a	ISM_SP500_1	73,20%	0,0002	101,8238	0,33782
11a	SP500_SP400_2	69,50%	0,0003	102,6331	0,33366
12a	ISM_SP500_1	76,80%	0,0003	103,4295	0,32706
13a	ISM_USDpln_2	76,80%	0,0005	104,8172	0,32324
14a	ISM_USDpln_2	76,80%	0,0007	105,9185	0,3193
15a	ISM_USDpln_2	75,60%	0,0009	107,2116	0,31498
16a	PrPrzUs_Inf_2	75,60%	0,0015	109,0837	0,31402
17a	PrPrzUs_Inf_2	73,20%	0,002	110,4573	0,31202
18a	SP500_SP400_2	73,20%	0,0019	110,8769	0,30462
19a	SP500_SP400_2	72,00%	0,0031	112,8479	0,30464
20a	PrPrzUs_Inf_2	73,20%	0,0029	113,1797	0,29781

Źródło: Opracowanie własne.

Tabela 10. Model otrzymany algorytmem regresji krokowej wstecznej.

Model	Liczba przyp. popr. pred.	Test ilorazu wiaryg.	Akaike'a	Śr. błąd absolutny
39	74,40%	[0,0000]	98,95487	0,35002

Źródło: Opracowanie własne

Po analizie dopasowań wszystkich modeli wybrano 3 modele.

- Model 1 - model 12a okazał się optymalny pod względem ilorazu szans,
- Model 2 - model 20 był optymalny pod względem średniego błędu absolutnego.
- Model 3 - model 39 był optymalny zarówno pod względem testu ilorazu wiarygodności, jak i kryterium informacyjnym Akaike'a ,

Dodatkowo skonstruowano model ważony, dla którego wag dostarczyły średnie z modelu 1, modelu 2 i modelu 3.

Model 1

Estymacja Probit, wykorzystane obserwacje 3/1995 – 12/2001

Zmienna zależna: Spread Wig20 – sWig80

	współczynnik	błąd standardowy	t-Studenta	wartość p
const	0,00268345	0,190242	0,01411	0,9887
USDjpy_1	6,71932	4,9476	1,358	0,1744
ISM_SP500_3	-13,8939	5,79163	-2,399	0,0164 *
ISM_1	8,07639	8,09324	0,9979	0,3183
ISM_USDpln_1	11,5525	6,97661	1,656	0,0977 *
SP400_3	-31,447	28,8094	-1,092	0,275
SP100_SP400_3	-30,1962	25,0089	-1,207	0,2273
SP500_3	23,4963	30,9649	0,7588	0,448
Mied_1	-3,78889	2,63584	-1,437	0,1506
SP500_SP400_2	2,99506	6,75864	0,4431	0,6577
ISM_USDpln_2	2,42529	7,79862	0,311	0,7558
ISM_2	-9,00585	8,29677	-1,085	0,2777

Logarytm wiarygodności -39,71477 Kryt. inform. Akaike'a 103,4295

Liczba przypadków 'poprawnej predykcji' = 63 (76,8%)

Test ilorazu wiarygodności: Chi-kwadrat(11) = 34,1978 [0,0003]

Model 2

Estymacja Probit, wykorzystane obserwacje 3/1995 – 12/2001

Zmienna zależna: Spread Wig20 – sWig80

	współczynnik	błąd standardowy	t-Studenta	wartość p
const	0,20972	0,312838	0,6704	0,5026
OblUs30_Zloto_2	-4,26497	4,24266	-1,005	0,3148
PPrzUS_2	-33,4581	95,3897	-0,3508	0,7258
PrPrzUs_Inf_2	0,0814038	0,914559	0,08901	0,9291
Zloto_SP100_1	5,45221	5,69425	0,9575	0,3383
Mied_1	-3,08799	2,81623	-1,096	0,2729
SP500_3	25,2654	33,5969	0,752	0,452
SP400_1	-8,71795	7,62786	-1,143	0,2531
SP400_2	0,979026	4,85274	0,2017	0,8401
SP400_3	-38,3869	33,2079	-1,156	0,2477
SP100_SP400_3	-35,9893	27,7226	-1,298	0,1942
SP500_SP400_2	3,04145	9,08705	0,3347	0,7379
Soja_1	-3,99576	3,20153	-1,248	0,212
Usdpln_SP500_3	-9,59872	9,74055	-0,9854	0,3244
USDjpy_1	9,32242	5,84976	1,594	0,111
ISM_1	24,3257	13,829	1,759	0,0786 *
ISM_2	-6,6301	9,58216	-0,6919	0,489
ISM_SP500_1	-15,9623	11,6594	-1,369	0,171
ISM_SP500_3	-10,9364	6,47102	-1,69	0,091 *
ISM_USDpln_1	13,783	8,30583	1,659	0,097 *
ISM_USDpln_2	5,01042	8,75598	0,5722	0,5672

Logarytm wiarygodności -36,58587 Kryt. inform. Akaike'a 115,1717

Liczba przypadków 'poprawnej predykcji' = 59 (72,0%)

Test ilorazu wiarygodności: Chi-kwadrat(20) = 40,4556 [0,0044]

Model 3

Estymacja Probit, wykorzystane obserwacje 1-82

Zmienna zależna: Spread Wig20 – sWig80

	współczynnik	błąd standardowy	t-Studenta	wartość p
const	0,0165473	0,167993	0,0985	0,9215
USDjpy_1	7,61161	4,61564	1,649	0,0991 *
ISM_SP500_3	-6,71212	3,12725	-2,146	0,0318 **
ISM_USDpln_1	15,7133	4,41858	3,556	0,0004 ***
SP100_SP400_3	-6,26967	4,89571	-1,281	0,2003
Soja_1	-4,74557	2,77271	-1,712	0,087 *

Logarytm wiarygodności -42,49645 Kryt. inform. Akaike'a 96,99290

Liczba przypadków 'poprawnej predykcji' = 61 (74,4%)

Test ilorazu wiarygodności: Chi-kwadrat(5) = 28,6345 [0,0000]

Następnie autor estymował te same modele dokładając obserwacje ze zbioru testowego. W tabeli 11 porównano modele w celu sprawdzenia czy zmienne, które były istotne dla zbioru treningowego również będą istotne dla całego zbioru obserwacji, testując ich stabilność. Wartość p podana w tabeli 11 odnośnie danej zmiennej w zbiorze treningowym.

Tabela 11. Zmienne istotne w danych modelach dla zbioru treningowego i testowego.

<u>Model 1</u>		<u>Model 2</u>		<u>Model 3</u>	
Zmienna	wartość p	Zmienna	wartość p	Zmienna	wartość p
ISM_SP500_3	0,0708 *	ISM_SP500_3	0,0765 *	ISM_USDpln_1	0,0015 ***
ISM_USDpln_1	0,0024 ***	ISM_USDpln_1	0,0045 ***		
Miedz_1	0,0024 ***	Miedz_1	0,0029 ***		
Liczba przypadków poprawnej predykcji					
68,40%		69,60%		68,40%	

Źródło: Opracowanie własne.

Po wyselekcjonowaniu modeli, przystąpiono do budowy prognoz. Autor zdecydował się na dwa podejścia do tego problemu.

Podejście pierwsze polegało na dynamicznym ujęciu prognozowania na podstawie modeli probitowych.

Autor dysponując danym zbiorem uczącym z okresu 3/1995 do 12/2001 prognozował na 12 miesięcy naprzód. Po dokonaniu prognozy, kolejnym krokiem było dodanie wygasłych prognoz do zbioru uczącego. Po każdym takim etapie do zbioru uczącego przypisywano wygasłe prognozy z ostatnich 12 miesięcy i jednocześnie nie odcinano obserwacji starszych. Tym samym zbiór uczący powiększał się z każdym etapem poprzez dodawanie nowszych obserwacji do zbioru uczącego się. W ramach tego podejścia zastosowano 2 strategie konstrukcji portfela:

- 1) Strategia 1. Otrzymana prognoza zwracała wagę jaką w danym miesiącu przypisano w portfelu dla Wig20 i sWig80. Suma wag = 100.
- 2) Strategia 2. Otrzymana prognoza zwracała decyzję czy cały kapitał będzie lokowany w Wig20, czy sWig80. Jeśli otrzymana wartość była większa lub równa od 0,5 wówczas cały kapitał lokowano w Wig20, w przeciwnym wypadku cały kapitał było lokowany w sWig80.

Tabele 12 i 13 zawierają wyniki zastosowania podejścia 1 w porównaniu ze strategią kup i trzymaj oraz strategią momentum.

Tabela 12. Wyniki portfela opartego na strategii 1.

	Model 1	Model 2	Model 3	Model ważony	Kup i trzymaj	Momentum
Stopa zwrotu / odchylenie stand.	19,92	20,58	20,03	20,28	16,61	11,29
Skumulowana stopa zwrotu	150,66%	162,27%	158,45%	157,13%	124,52%	88,51%
Średnia miesięczna stopa zwrotu	1,67%	1,80%	1,76%	1,75%	1,38%	0,98%
Odchylenie standardowe	7,56%	7,89%	7,91%	7,75%	7,50%	7,84%

Źródło: Opracowanie własne.


Tabela 13. Wyniki portfela opartego na strategii 2.

	Model 1	Model 2	Model 3	Model ważony
Wskaźnik stopa zwrotu / odchylenie standardowe	25,12	19,27	20,73	20,98
Skumulowana stopa zwrotu	198,07%	161,28%	169,76%	171,32%
Średnia miesięczna stopa zwrotu	2,20%	1,79%	1,89%	1,90%
Odchylenie standardowe	7,88%	8,37%	8,19%	8,17%

Źródło: Opracowanie własne

Wykres 3 i wykres 4 przedstawiają graficzne porównanie zyskowności poszczególnych metod. Jako metodę reprezentującą model probitowy autor przyjął model ważony.

Wykres 3. Skumulowana stopa zwrotu. Podejście 1. Strategia 1.




Źródło: Opracowanie własne.

Wykresy 5 i 6 przedstawiają graficzne porównanie kształtowania się spreadu między modelem ważonym, a strategią kup i trzymaj.

Podejście drugie, wyniki w tabelach 14 i 15, polegało na statycznym ujęciu prognozowania na podstawie modeli probitowych. Autor dysponując danym zbiorem uczącym z okresu 3/1995 do 12/2001 przeprowadzał prognozy na 90 miesięcy naprzód, nie dodając przy tym wygasłych prognoz do zbioru uczącego się. W ramach tego podejścia zastosowano identyczne strategie konstrukcji portfela jak w przypadku prognozowania dynamicznego.


Wykres 4. Skumulowana stopa zwrotu. Podejście 1. Strategia 2.



Źródło: Opracowanie własne.

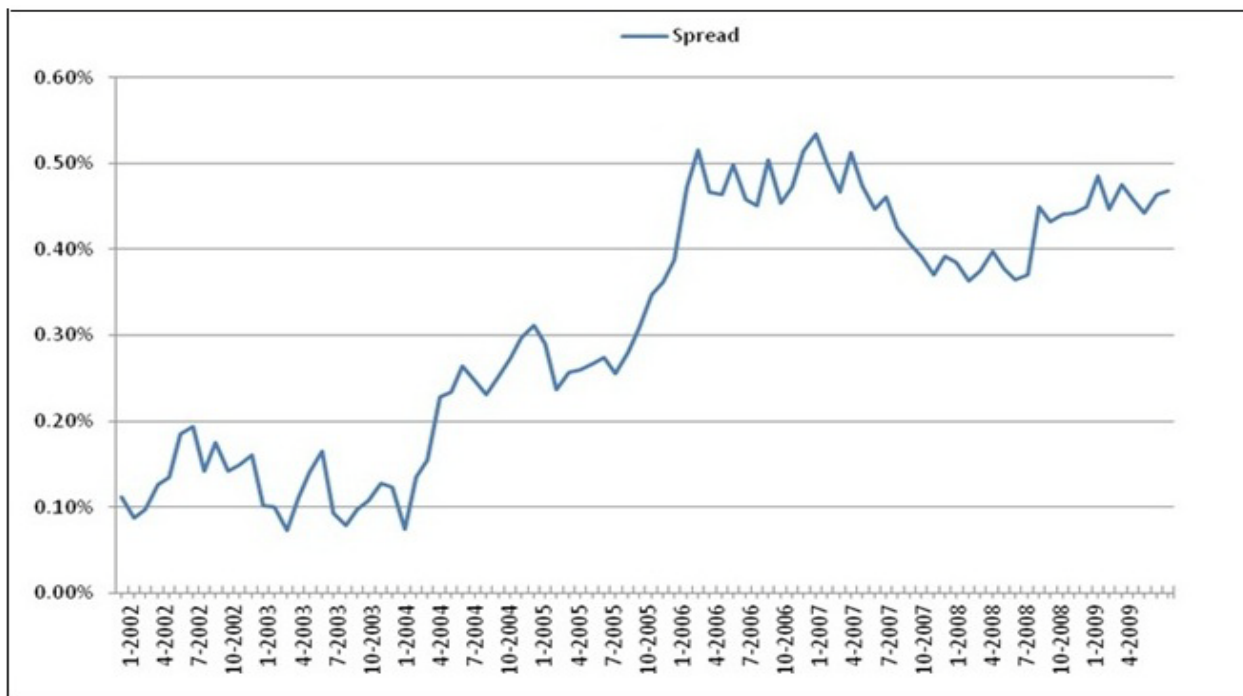
Wykres 5. Spread w ujęciu procentowym między modelem ważonym, a strategią kup i trzymaj.

Podejście 1. Strategia 1.



Źródło: Opracowanie własne.

Wykres 6. Spread w ujęciu procentowym między modelem ważonym, a strategią kup i trzymaj.
Podejście 1. Strategia 2.



Źródło: Opracowanie własne.

Tabela 14. Wyniki portfela opartego na strategii 1.

	Model 1	Model 2	Model 3	Model ważony	Kup i trzymaj	Momentum
Stopa zwrotu / odchylenie standardowe	20,66	21,26	20,04	20,72	16,61	11,29
Skumulowana stopa zwrotu	157,34%	166,49%	155,89%	159,91%	124,52%	88,51%
Średnia miesięczna stopa zwrotu	1,75%	1,85%	1,73%	1,78%	1,38%	0,98%
Odchylenie standardowe	7,61%	7,83%	7,78%	7,72%	7,50%	7,84%

Źródło: Opracowanie własne.

Wykres 7 i wykres 8 przedstawiają graficzne porównanie zyskowności poszczególnych metod. Jako metodę reprezentującą model probitowy autor przyjął model ważony.


Wykresy 9 i 10 przedstawiają graficzne porównanie kształtowania się spreadu między modelem ważonym, a strategią kup i trzymaj.

Tabela 15. Wyniki portfela opartego na strategii 2.

	Model 1	Model 2	Model 3	Model ważony
Stopa zwrotu / odchylenie standardowe	22,61	23,46	21,26	23,33
Skumulowana stopa zwrotu	179,99%	192,23%	169,53%	184,46%
Średnia miesięczna stopa zwrotu	2,00%	2,14%	1,88%	2,05%
Odchylenie standardowe	7,96%	8,20%	7,97%	7,91%


Źródło: Opracowanie własne.

Wykres 7. Skumulowana stopa zwrotu. Podejście 2. Strategia 1




Źródło: Opracowanie własne.

Wykres 8. Skumulowana stopa zwrotu. Podejście 2. Strategia 2



Źródło: Opracowanie własne.


Wykres 9. Spread w ujęciu procentowym między modelem ważonym, a strategią kup i trzymaj. Podejście 2. Strategia 1.



Źródło: Opracowanie własne.

Wykres 10. Spread w ujęciu procentowym między modelem ważonym, a strategią kup i trzymaj.

Podejście 2. Strategia 2.



Źródło: Opracowanie własne.

Kolejnym etapem było obliczenie stóp miar ryzyka i stopy zwrotu według kryteriów wyboru modeli. Wnioski, zob. tabela 16, tej analizy może zniekształcić fakt, iż kierując się 4 kryteriami wybrano tylko 3 modele. Było to podyktowane tym, iż model 3 był optymalny pod względem dwóch kryteriów. Jednak takie rozwiązanie pozwoliło znaleźć odpowiedź na pytanie czy model efektywny pod więcej niż dwoma względami jest skuteczniejszy od modeli efektywnych pod jednym względem.

W celu otrzymania wyników autor uśrednił poszczególne modele z obu podejść i obu strategii.

Tabela 16. Wyniki według przyjętych kryteriów dobroci modelu.

	Stopa zwrotu / odchylenie standardowe	Skumulowana stopa zwrotu
Test ilorazu wiarygodności oraz kryterium Akaike'a	20,51	163,41%
Iloraz szans	22,08	171,52%
Absolutny błąd prognozy	21,14	170,57%

Źródło: Opracowanie własne.

3.5. Analiza wyników.

Wyniki zaprezentowane w tabelach 12 – 15 dają odpowiedź na pytanie zadane na początku rozdziału. Można zatem stwierdzić, iż krótkoterminowe odchylenia w stopach zwrotu na spreadzie między indeksami dużych i małych spółek mogą być lepiej wyjaśniane przez modele probitowe w porównaniu ze strategią kup i sprzedaj oraz strategią momentum.

Autor znalazł również odpowiedzi na pytania poboczne. Kryterium dobroci modelu, które najlepiej opisuje odchylenia na spreadzie Wig20 – sWig80 okazał się iloraz szans. Dodatkowo okazało się, iż model 3, który był optymalny pod względem dwóch kryteriów nie wyróżnił się pozytywnie na tle pozostałych.

Jak pokazują wyniki badań zastosowanie dywersyfikacji w przypadku tak silnie skorelowanych instrumentów nie daje pozytywnych wyników. Okazało się bowiem, iż w celu maksymalizacji wskaźnika (stopa zwrotu / odchylenie standardowe) należy cały kapitał inwestować w Wig20 lub sWig80.

3.5.1. Analiza zmiennych wpływających na przyszłe zachowanie się spreadu Wig20-sWig80.

Autor przeprowadził analizę czynników mających największy wpływ na odchylenia na spreadzie między indeksami dużych i małych spółek. Wyniki testu Sims'a dowodzą, że do najistotniejszych czynników należą zmienne oparte na wzajemnych relacjach.

Za najbardziej istotną zmienną wyprzedzającą, która wpływa na badany spread okazała się różnica procentowa między zmianą indeksu ISM a indeksu S&P500 w czasie t-1 w stosunku do zmiany spreadu między Wig20 a sWig80. W modelu 3 współczynnik przy tej zmiennej wynosi -15,96 co oznacza, iż mniejsza procentowa zmiana indeksu ISM, niż indeksu S&P500 powoduje w następnym miesiącu przewagę indeksu Wig20 nad sWig80. Warto tutaj zaznaczyć, iż badacz prognozując spread Wig20-sWig80 w miesiącu styczniu ma do dyspozycji daną dla ISM za listopad z okolicy 15 grudnia, natomiast dana dla indeksu S&P 500 za grudzień dostępna jest z dnia 31 grudnia. Implikuje to kolejny wniosek; zmienna ISM-SP500_1 opisuje zależność między zmianą indeksu ISM w czasie t-2 oraz zmianą indeksu S&P 500 w czasie t-1 w stosunku do zmiany spreadu Wig20-sWig80. Należy zatem stwierdzić, iż mniejsze zmiany indeksu ISM w okresie t-2 od zmiany indeksu S&P 500 w okresie t-1 powoduje przewagę Wig20 nad sWig80 w okresie t. Można na podstawie takich wyników badań wysnuć wniosek, iż jeśli menadżerowie do spraw zaopatrzenia prognozują zmiany zakupów w czasie t-2 na poziomie niższym niż zmiana

indeksu S&P 500 w okresie t-1 wówczas można się spodziewać przewagi Wig20 nad sWig80 w okresie t.

Kolejną zmienną bardzo istotną dla omawianego zagadnienia jest zmiana kursu walutowego dolar/złoty w okresie t-1 w stosunku do spreadu Wig20 – sWig80. We wszystkich 3 modelach współczynnik przy zmiennej USDpln jest dodatni. Według zaprezentowanych modeli osłabiająca się złotówka względem dolara w czasie t-1 skłania inwestorów do przeszacowywania spółek z indeksu Wig20 nad spółkami z indeksu sWig80 w czasie t. Wzrost wartości dolara to zwiększenie awersji do ryzyka na globalnych rynkach finansowych. Przekładając to na rynek polski, zwiększona awersja do ryzyka powoduje przeszacowywanie spółek dużych względem małych. Spółki te, są narażone na większe ryzyko rynkowe.

Ciekawe zjawisko można zaobserwować wśród zmiennych surowcowych. Do „rankingu Sims’a” weszły dwie zmienne: miedz_1 oraz soja_1. Obie zmienne reprezentują opóźnienie względem spreadu Wig20 i sWig80 o jeden okres. Zgodnie z zaprezentowanymi modelami dodatnia zmiana tych surowców zapowiada przewagę sWig80 nad Wig20 w następnym miesiącu. Jest to interesująca obserwacja szczególnie w przypadku zmiennej miedz_1, której zmiany mają decydujący wpływ na notowania jednej z największych spółek w indeksie Wig20 – KGHM. Można wyciągnąć wniosek, że rosnące ceny miedzi nie przekładają się na dominację spółek dużych nad małymi, mimo, że udział KGHM w indeksie Wig20 jest istotny.

Kolejną zmienną godną uwagi jest spread między złotem, a indeksem S&P 100. Rozszerzający się spread jest oznaką możliwej w przyszłości przewagi indeksu dużych spółek nad małymi spółkami na Warszawskiej Giełdzie Papierów Wartościowych.

Analizując estymowane modele w dwóch okresach; pierwszym - w okresie reprezentującym zbiór treningowy oraz w drugim dotyczącym całego zbioru obserwacji, nasuwają się interesujące wnioski (tabela 11). Zmienne istotne w modelu 1 dla pierwszego okresu ponownie były istotne w modelu dla okresu drugiego. Natomiast dodatkowo bardzo istotną zmienną dla okresu drugiego okazały się zmiany cen miedzi z poprzedniego okresu. W modelu 2 można zauważyć, że tylko zmienne ISM_SP500_3 oraz ISM_USDpln_1 utrzymały wysoki poziom istotności. Dodatkowo, podobnie jak w modelu 1, do zbioru zmiennych istotnych dla całego okresu dołączyła zmienna miedz_1. Duże zmiany na przestrzeni obu okresów zaszły w modelu 3. Spośród czterech zmiennych istotnych dla pierwszego okresu, tylko zmienna ISM_USDpln_1 okazała się stabilną zmienną objaśniającą.

Dodatkowo w tej samej tabeli można zauważyć, że jedno z najważniejszych kryteriów dobroci dla modeli dwumianowych – iloraz szans – jest bardzo podobny dla wszystkich trzech modeli. Występują jednak różnice między okresem pierwszym i drugim dla tego kryterium. Interesujący jest fakt, że kryterium to najmniej się zmienia dla modelu 2 (okres pierwszy – 72%, okres drugi – 68,6%).

3.5.2. Analiza skuteczności modeli probitowych.

Wyniki osiągnięte przez wszystkie 4 modele probitowe zdecydowanie przewyższają benchmark jakim jest metoda kup i trzymaj. Analizując poszczególne podejścia i ujęte w nich strategie należy zauważyć, iż zdecydowanie lepiej spisywały się modele w podejściu 2. Może to oznaczać, iż dodawanie najnowszych obserwacji do zbioru uczącego się nie wpływa pozytywnie na skuteczność modelu. Wydaje się, iż pewne relacje na rynkach finansowych nie zmieniają się na tyle szybko aby dodanie nowych obserwacji miało pozytywny wpływ na relację zysku do ryzyka. Trwałość tych relacji powoduje, że modele w podejściu 2 wykazują lepsze parametry w porównaniu do modeli w podejściu 1.

Dodatkowo warto zauważyć, iż modele w strategiach 2 wykazują średnio lepsze parametry w porównaniu z modelami ze strategii 1. Zgodnie z oczekiwaniami, modele te posiadają średnio wyższe odchylenia standardowe, jednak stosunek zysku do ryzyka wskazuje, że modele te zdecydowanie lepiej spisują się w wychwytywaniu odchyłeń na spreadzie Wig20-sWig80.

Podsumowując, można stwierdzić, iż strategia 2 w podejściu 2 jest dobrym wyborem z punktu widzenia maksymalizacji wskaźnika zysku do ryzyka.

3.5.3. Analiza przyczyn skuteczności zaprezentowanych modeli probitowych.

W polskiej oraz światowej literaturze nie występują opracowania na temat zastosowania modeli probitowych do wyjaśniania odchyłeń na spreadzie Wig20 – sWig80. Występują natomiast opracowania dotyczące spółek małych i dużych na innych rynkach. Punktem odniesienia i jednocześnie inspiracją do badania tego obszaru było opracowanie autorów Bhavesh Gokani and Natasha Todorovic¹⁷, pod tytułem. Autorzy w tym opracowaniu badali odchylenia na spreadzie między małymi i dużymi spółkami na rynku angielskim. Ich modele probitowe okazały się zdecydowanie skuteczniejsze w porównaniu analogicznymi strategiami typu kup i trzymaj.

¹⁷ Gokani B., Todorovic N. [2006] *Profitability of Quantitative vs. Momentum Size and Style Rotation Strategies in the UK Equity Market*

Autorzy w swojej pracy zwracają uwagę jak istotny jest dobór zmiennych i odpowiednia ich transformacja do potrzeb prognozowania tego typu szeregów czasowych.

Zaprezentowane modele probitowe w tej pracy posiadają wszystkie właściwości ujęte w modelach Gokani i Todorovic'a oraz wprowadzają do probitowego prognozowania finansowych szeregów czasowych nowe elementy. Przede wszystkim autor zastosował unikalny algorytm selekcji zmiennych oraz wyboru optymalnego modelu. W pierwszym etapie skonstruowano ranking na podstawie testu Sims'a, po czym owy ranking wykorzystano do modelowania probitowego, którego celem było znalezienie modeli optymalnych pod względem 4 kryteriów dobroci modelu. W następnym rozdziale zostanie zaprezentowany rozszerzony algorytm.

Rozdział IV

Wykorzystanie modelu probitowego w procesie alokacji aktywów między indeksy S&P 500 i Dow Jones Industrial Average (DJIA).

Autor w niniejszym rozdziale przedstawi autorską aplikację „Probit Optimizer” w celu zbadania możliwości wykorzystania modelu probitowego w procesie alokacji aktywów między indeks SP 500 oraz Dow Jones Industrial Average.

4.1. Charakterystyka opisowa indeksów SP 500 i DJIA.

S&P 500 jest indeksem w skład którego wchodzi 500 firm o największej kapitalizacji, notowanych na New York Stock Exchange i NASDAQ. Są to głównie firmy amerykańskie. Indeks ten jest najbardziej znanym wskaźnikiem zarządzanym przez Standard & Poor's, Dow Jones Industrial Average (DJIA) – to jeden z najważniejszych indeksów akcji spółek notowanych na Giełdzie Papierów Wartościowych w Nowym Jorku (New York Stock Exchange) i Nasdaq. Indeks ten został stworzony przez Charlesa Dowa i statystyka Edwarda Jonesa. Indeks Dow Jones jest najstarszym działającym indeksem akcji w Stanach Zjednoczonych. Obecnie składa się on z 30 największych amerykańskich przedsiębiorstw.

Statystyki opisowe dotyczące obu indeksów przedstawia tabela 17.

Przedstawione w tabeli 17 statystyki wskazują, iż oba indeksy mają podobne charakterystyki. Nieco większe ryzyko niesie za sobą inwestycja w indeks SP 500. Porównując relacje stopy zwrotu do odchylenia standardowego można zauważyć, iż inwestując w podanym okresie w indeks DJIA osiągnęłoby się o prawie 10 % wyższą stopę zwrotu przy nieco niższym ryzyku.


Tabela 17. Podsumowanie ilościowe indeksów SP 500 i DJIA za okres 1/1995 – 6/2009 w ujęciu miesięcznym.

Indeks	Średnia stopa zwrotu	Skumulowana stopa zwrotu	Odchylenie standardowe	Minimalna stopa zwrotu	Maksymalna stopa zwrotu	Rozstęp stóp zwrotu
SP 500	0,40%	69,40%	0,0463	-18,42%	9,23%	27,66%
DJIA	0,45%	78,99%	0,0456	-16,40%	10,08%	26,48%

Opracowanie: Źródło własne.

Wykres 11 przedstawia skumulowany spread w ujęciu procentowym między indeksem S&P 500 i indeksem DJIA.

Wykres 11. Skumulowany spread między SP 500 i DJIA w ujęciu procentowym.



Źródło: Opracowanie własne.

Na powyższym wykresie można zauważyć, że spread między tymi instrumentami wykazuje się mniejszą zmiennością niż spread między sWig80 i Wig20. W maksymalnym punkcie dochodzi on do 15%.

4.2. Hipotezy i cele badawcze.

Mając na uwadze wyniki z rozdziału pierwszego autor przeprowadzi dodatkowe badania aby potwierdzić tezę, iż modele ze strategii 2 spisują się lepiej niż modele ze strategii 1, co w praktyce może oznaczać, iż modele probitowe są skuteczniejsze w określaniu kierunku zmian niż w dokładnym określaniu prawdopodobieństwa tej zmiany. Takie przypuszczenie w odniesieniu do modeli logitowych sformułowali w swojej pracy Amenc, Malaise, Martellini i Sfeir (2003).

Autor porówna najbardziej efektywne modele pod względem możliwości zastosowania ich w procesie alokacji aktywów i wykorzystując aplikację „Probit Optimizer” odpowie na pytanie:

- Czy modele dwu wymiarowe są bardziej efektywne niż modele trzy wymiarowe w kontekście stopy zwrotu i wskaźnika stopa zwrotu/odchylenie standardowe.

4.3. Metodologia badania.

Autor w tej części pracy zastosuje inną metodę badawczą. Proces alokacji aktywów będzie się nadal odbywał za pomocą prognoz z modelu probitowego jednak zostanie usunięty etap selekcji zmiennych objaśniających. W jego miejsce autor wykorzysta autorską aplikację o nazwie „Probit Optimizer”.

Głównym celem jaki przyświeca wykorzystaniu powyższej aplikacji jest możliwość pominięcia etapu badania przyczynowości między zmiennymi objaśniającymi, a zmienną objaśnianą. W ten sposób autor zrezygnuje z przeprowadzenia testu Simsa.

Aplikacja „Probit Optimizer” (PO) w sposób automatyczny estymuje wszystkie możliwe modele z danego zbioru. Jest to aplikacja napisana w języku C++, której głównym zadaniem jest wymuszanie działania programu zewnętrznego jakim w tym przypadku jest Gretl oraz wyświetlaniem wyników przeprowadzonych estymacji, które wykonuje Gretl. Jeśli mamy zbiór zmiennych objaśniających złożony z k -elementów, z którego chcemy zbadać wszystkie możliwe modele n -elementowe dla 1 zmiennej objaśnianej, to ilość możliwych kombinacji można zapisać w sposób następujący:

$$n!/k!(n-k)!$$

Aplikacja PO w sposób automatyczny estymuje model po modelu. Aplikacja ta ma możliwość filtrowania wyników według dowolnego kryterium. Przykładowy obraz działania przedstawiają obrazy 1 i 2.

W ramach badania spreadu SP 500 – DJIA, autor zastosuje ten sam zbiór zmiennych objaśniających, który był użyty do badania spreadu między małymi i dużymi spółkami. Autor postanowił jednak usunąć opóźnienia dla niektórych zmiennych. W ten sposób zbiór zmiennych zawierał 102 regresory wyszczególnione w tabeli 5 oraz 6. Dodatkowo autor dodał interakcje między zmiennymi oraz wartości kwadratowe niektórych zmiennych.

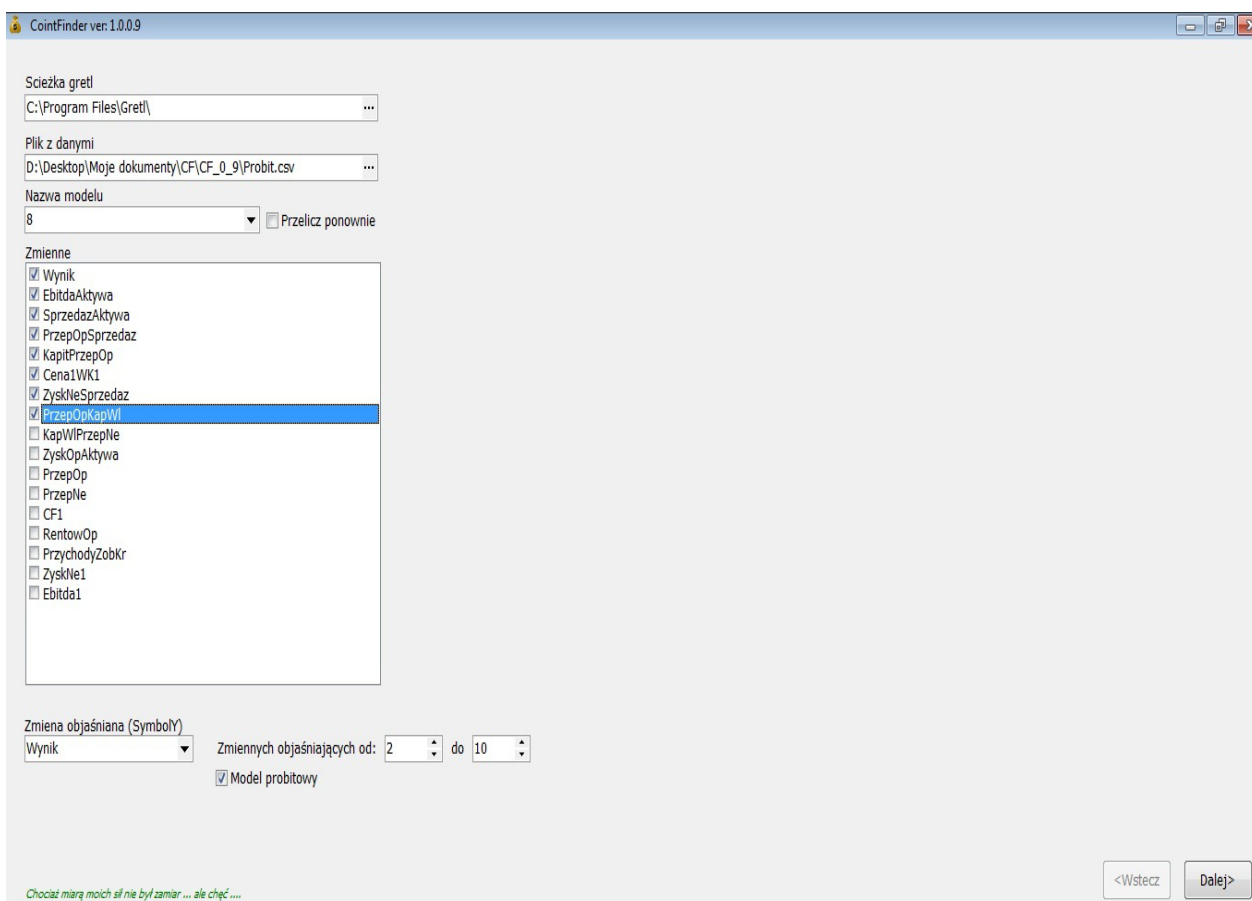
Aplikacja PO będzie miała za zadanie wyszukać wszystkie i wyestymować modele z 2 i 3 zmiennymi objaśniającymi¹⁸. Kryteriami wyboru efektywnych modeli będą:

- Test ilorazu wiarygodności

¹⁸ Ze względu na zapotrzebowanie na moce obliczeniowe przy skanowaniu modeli z większą ilością zmiennych objaśnianych autor postanowił ograniczyć wymiar modeli.

- Iloraz szans

Obraz 1. Moduł wyboru zmiennych objaśniających oraz wymiaru modelu.



Źródło: Opracowanie własne na podstawie aplikacji „Probit Optimizer”.

Wyselekcjonowane zostaną 4 modele, które spełniają następujące warunki:

Model 1 – najniższa wartość testu ilorazu wiarygodności z pośród 2-wymiarowych modeli.

Model 2 - najwyższa wartość testu ilorazu szans z pośród 2-wymiarowych modeli.

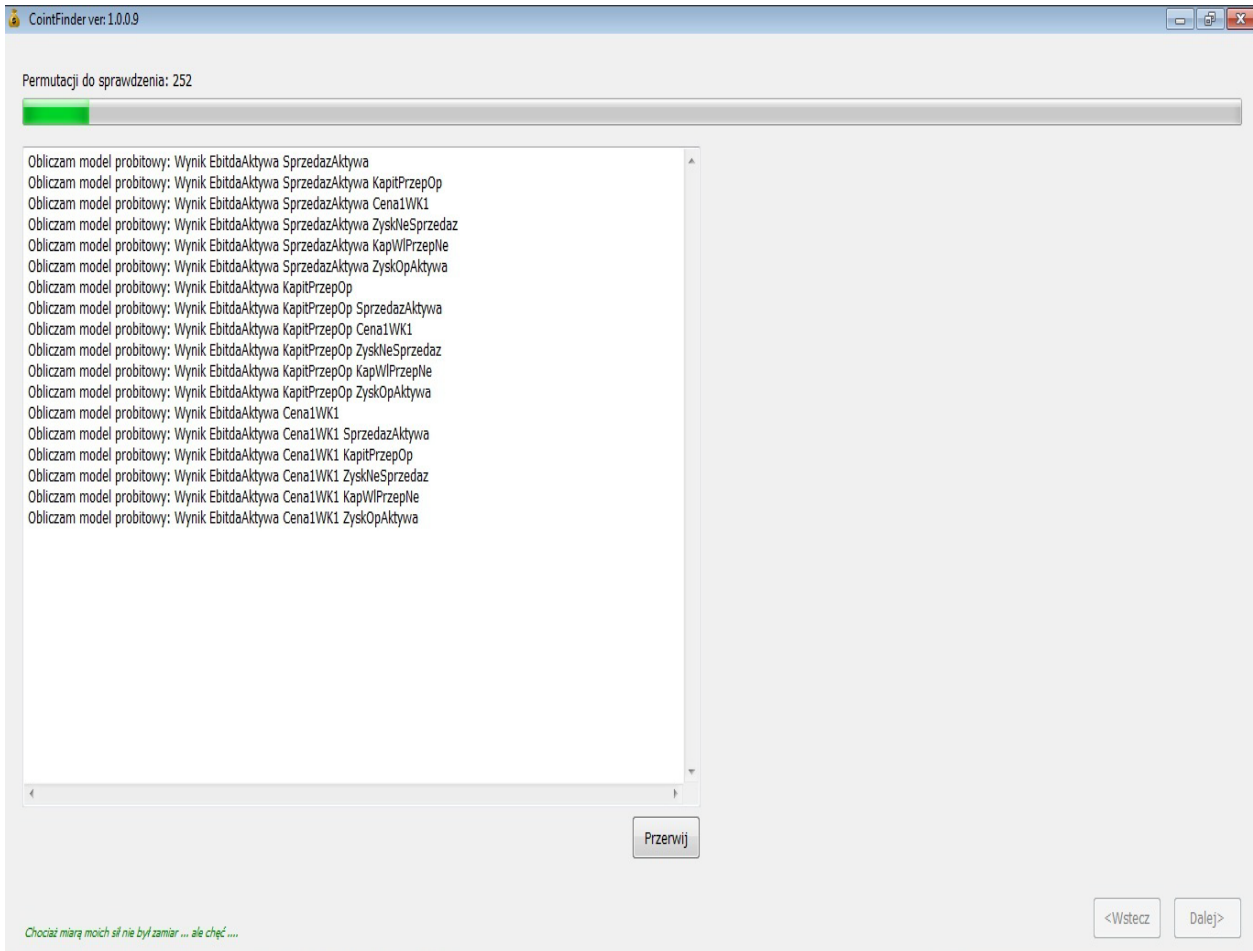
Model 3 – najniższa wartość testu ilorazu wiarygodności z pośród 3-wymiarowych modeli.

Model 4 - najwyższa wartość testu ilorazu szans z pośród 3-wymiarowych modeli.

Zbiór treningowy składa się z 84 okresów, od stycznia 1995 do grudnia 2001 roku.

Natomiast okres testowy zawiera się między styczniem 2002, a lipcem 2009 roku i składa się z 91 okresów.

Obraz 2. Moduł estymacji modeli.



Źródło: Opracowanie własne na podstawie aplikacji „Probit Optimizer”.

W ramach estymacji modeli 2-wymiarowych sprawdzono 5120 kombinacji, natomiast w ramach estymacji modeli 3-wymiarowych sprawdzono 171 700 kombinacji.

Analizowany model będzie miał postać:

$$P(Y_{t+1} = 1|x) = P(y=1|X_t)$$

gdzie,

X_t – zmienne objaśniające

$Y_{t+1} = 1$, jeśli różnica w ujęciu procentowym między SP 500 a Dow Jones będzie dodatnia w okresie jednego miesiąca naprzód względem zmiennych objaśniających, w przeciwnym wypadku $Y_{t+1} = 0$.

Wybrano następujące modele:

Model 1: Probit, Użyte obserwacje 01/1995 - 12/2001

Zmienna zależna: Spread SP 500 – DJIA

	<u>współczynnik</u>	<u>błąd standardowy</u>	<u>test t</u>	<u>p-wartość</u>	
OblUs10_2	8,18949	3,49125	2,346	0,019	**
PPrzUs_InfUs_3	0,726257	0,267004	2,72	0,0065	***

Liczba przypadków 'poprawnej predykcji' = 49 (60,5%)

Test ilorazu wiarygodności: Chi-kwadrat = 13,573 [0,0011]

Model 2: Probit, Użyte obserwacje 01/1995 - 12/2001

Zmienna zależna: Spread SP 500 - DJIA

	<u>współczynnik</u>	<u>błąd standardowy</u>	<u>test t</u>	<u>p-wartość</u>	
PPrzUs_InfUs	0,518154	0,238222	2,175	0,0296	**
M2Eur_3	-40,507	26,4157	-1,533	0,1252	

Liczba przypadków 'poprawnej predykcji' = 57 (70,4%)

Test ilorazu wiarygodności: Chi-kwadrat = 6,66841 [0,0356]

Model 3: Probit, Użyte obserwacje 01/1995 - 12/2001

Zmienna zależna: Spread SP 500 - DJIA

	<u>współczynnik</u>	<u>błąd standardowy</u>	<u>test t</u>	<u>p-wartość</u>	
OblUs10_Bund	0,167374	0,0801575	2,088	0,0308	**
OblUs10_2	8,66909	3,59395	2,412	0,0139	**
PPrzUs_InfUs_3	0,847337	0,278307	3,045	0,0042	**

Liczba przypadków 'poprawnej predykcji' = 57 (70,4%)

Test ilorazu wiarygodności: Chi-kwadrat = 18,1797 [0,0004]

Model 4: Probit, Użyte obserwacje 01/1995 - 12/2001

Zmienna zależna: Spread SP 500 - DJIA

	<u>współczynnik</u>	<u>błąd standardowy</u>	<u>test t</u>	<u>p-wartość</u>
Bund	16,447	10,623	1,548	0,1233
Brent _2^2 ¹⁹	-18,172	10,236	-1,775	0,0760
PPrzUs_InfUs_3	0,6237	0,2603	2,456	0,0134 **

Liczba przypadków 'poprawnej predykcji' = 60 (74,1%)

Test ilorazu wiarygodności: Chi-kwadrat = 14,196 [0,0027]

Przedstawione powyżej modele stanowią podstawę do przeprowadzenia symulacji zachowanie się portfela aktywów. Po wyselekcjonowaniu modeli przez aplikację „Probit Optimizer”, przystąpiono do budowy prognoz. Autor zdecydował się na jedno podejście do tego problemu. Podejście to polegało na statycznym prognozowaniu składu portfela aktywów, którego zasady opisane już zostały w pkt 1.4. W ramach tego podejścia zastosowano identyczne strategie konstrukcji portfela opisane w pkt 1.4. Tabele 18 i 19 zawierają wyniki poszczególnych strategii.

Tabela 18. Strategia 1.

	Model 1	Model 2	Model 3	Model 4	Model wazony
Stopa zwrotu / odchylenie standardowe	-4,98	-3,99	-4,85	-4,69	-4,63
Skumulowana stopa zwrotu	-21,57%	-17,50%	-21,02%	-20,33%	-20,11%
Odchylenie standardowe	4,33%	4,39%	4,34%	4,34%	4,34%

Źródło: Opracowanie własne.

¹⁹ Zmienna Brent _2^2 jest kwadratem zmiennej Brent_2

Tabela 19. Strategia 2.

	Model 1	Model 2	Model 3	Model 4	Model ważony
Stopa zwrotu / odchylenie standardowe	-5,21	-3,00	-5,47	-3,45	-5,20
Skumulowana stopa zwrotu	-22,81%	-13,26%	-23,80%	-14,69%	-22,44%
Odchylenie standardowe	4,38%	4,41%	4,35%	4,25%	4,31%

Źródło: Opracowanie własne.

W analogicznym okresie strategia pasywna, równowazona typu kup i trzymaj osiągnęła następujące rezultaty w porównaniu do średnich wartości ze wszystkich modeli probitowych, tabela 20:

Tabela 20. Strategia pasywna.	Strategia pasywna	Modele probitowe
Stopa zwrotu / odchylenie standardowe	-4,44	-4,46
Skumulowana stopa zwrotu	-19,66%	-19,38%
Odchylenie standardowe	4,43%	4,34%

Źródło: Opracowanie własne.

Następnie autor porównał wyniki z podziałem na strategie, kryteria wyboru modelu oraz wymiar modelu. Tabele 21, 22, 23 prezentują średni wynik.

Tabela 21. Średnie wyniki według danej strategii.

	Stopa zwrotu / odchylenie standardowe	Skumulowana stopa zwrotu
Strategia 1	-4,63	-20,11%
Strategia 2	-4,28	-18,64%

Źródło: Opracowanie własne.

Tabela 22. Średnie wyniki według kryterium dobroci wyboru modelu.

	Stopa zwrotu / odchylenie standardowe	Skumulowana stopa zwrotu
Test ilorazu wiarygodności	-5,13	-22,30%
Iloraz szans	-3,78	-16,45%

Źródło: Opracowanie własne.


Tabela 23. Średnie wyniki według kryterium wymiaru modelu.

	Stopa zwrotu / odchylenie standadowe	Skumulowana stopa zwrotu
Modele z 2 zmiennymi	-4,30	-18,78%
Modele z 3 zmiennymi	-4,62	-19,96%

Źródło: Opracowanie własne.

Na wykresie 12 zobrazowano zachowanie się wybranych strategii względem strategii pasywnej. Na uwagę zwraca liniowy wzrost różnicy procentowej między stopą zwrotu dla modelu 2 w strategii 2 oraz strategią pasywną, czego dowodem jest wysoki współczynnik R^2 dla linii trendu. Z równania regresji liniowej można odczytać, że z miesiąca na miesiąc strategia 1 wykorzystująca model 2 pokonuje strategię pasywną średnio miesięcznie o 0,05%. Podobnie prezentuje się model 2 w strategii 2, z tym, że w tym przypadku średni miesięczny wzrost wynosi 0,02%.

Wykres 12. Różnica w ujęciu procentowym między najlepszymi modelami ze strategii 1 oraz 2.



Źródło: Opracowanie własne.

4.4. Analiza wyników.

Analizując wyniki przedstawionych modeli, które zostały wyselekcjonowane za pomocą aplikacji „Probit Optimizer” należy stwierdzić, iż podobnie jak w badaniu nad spreadem Wig20 – wWig80, modele probitowe lepiej sprawdzają się w strategii 2. Pozwala to potwierdzić tezę, iż modele probitowe są skuteczniejsze w określaniu kierunku zmian, niż w dokładnym określaniu prawdopodobieństwa tej zmiany. Potwierdziła się również teza, iż skuteczniejszym kryterium dobroci modelu jest ponownie iloraz szans. Modele, które były wybierane na podstawie tego kryterium osiągnęły stopę zwrotu wyższą średnio o ponad 1 % niż modele wybierane na podstawie kryterium testu ilorazu wiarygodności.

Interesujące wnioski można również wysunąć przypatrując się zmiennym, które weszły w skład modeli efektywnych. Okazało się, że żadna ze zmiennych prognozujących odchylenie między indeksami Wig20 i sWig80, nie weszła w skład modeli prognozujących spread między SP 500, a DJIA. Wynikać to może z dwóch faktów. Po pierwsze modele te selekcjonowane były według różnych metod i po drugie może to dowodzić, iż przyszłymi odchyleniami między polskimi indeksami, a amerykańskimi rządzi inne przyczyny.

Wprawdzie współczynniki modeli probitowych nie da się interpretować w sposób liniowy to jednak znak przy nich jest w pełni interpretowalny jak przy modelach estymowanych metodami najmniejszych kwadratów. Analiza najlepszego spośród modeli – Model2 dostarcza nam ciekawych wniosków. Okazuje się, iż dodatnia różnica procentowa między produkcją przemysłową w USA, a inflacją powoduje w następnym miesiącu przewagę indeksu SP 500 nad przemysłowymi spółkami z indeksu DJIA. Większe procentowe wzrosty lub mniejsze procentowe spadki produkcji przemysłowej niż inflacji były powodem w okresie 1995 – 2001 do przeważania indeksu SP 500 nad DJIA. Drugą zmienną w tym modelu jest agregat monetarny strefy Euro M2 opóźniony o 3 okresy. Oznacza to, iż odchylenie między SP 500, a DJIA reaguje przynajmniej z 3 miesięcznym opóźnieniem na zmiany podaży pieniądza. Ujemny znak przy tym współczynniku prowadzi do stwierdzenia, iż wcześniejsze zaostrzenie polityki dotyczącej rezerw obowiązkowych skutkować może w przyszłości (3 miesiące) wzrostem indeksu SP 500 względem indeksu DJIA.

Rozdział V

Wykorzystanie modelu probitowego w procesie alokacji aktywów między Złoto, S&P 500 i Dolar / Jen.

5.1. Wprowadzenie. Analiza dotychczasowej literatury.

Zagadnienie wykorzystania modeli ekonometrycznych do globalnej taktycznej alokacji aktywów jest szeroko opisywane w literaturze. Wielu badaczy starało się znaleźć najlepszy model używając różnych kryteriów wyboru zmiennych i modeli. Nam i Branch (1994) stworzyli strategię taktycznej alokacji aktywów pomiędzy weksłami skarbowymi amerykańskimi, a indeksem S&P 500. Zastosowali publicznie dostępne dane takie jak wskaźnik dywidenda/cena, poprzednia cena weksła skarbowego, zmiana ceny weksła skarbowego i wzrost zysku na akcję. Wykorzystując do tego model logitowy pokazali wyniki, które okazały się lepsze, niż strategia pasywna. Larsen i Woźniak (1995) stworzyli dwumiesięczną regułę inwestycyjną opartą na modelu logitowym, która miała za zadanie wskazywać czy inwestować w akcję lub w obligację oraz czy inwestować w akcję lub weksle skarbowe. Dla większości z 9 zmiennych objaśniających autorzy dołączyli do modelu dwa opóźnienia danej zmiennej. Taką samą operację autor zastosuje w dalszej części rozprawy doktorskiej poświęconej temu obszarowi badawczemu. Inne prace traktujące o wykorzystaniu weksli skarbowych, obligacji i akcji w procesie taktycznej alokacji aktywów napisali Kairys (1993), Breen, Golsten i Jagannathan (1989), Klemowski i Bharati (1995). Z kolei Pasaran i Timmerman (1993) za pomocą 9 zmiennych dokonywali co miesięcznej alokacji między obligacją i akcją przy użyciu modelu logitowego. Z ich obserwacji wynika, że zmienne objaśniające powinny być zmieniane gdy zmieniają się cykle gospodarcze. Jediną zmienną, która była zawarta w modelu przez cały okres, była opóźniona o jeden miesiąc aktualne oprocentowanie weksli skarbowych. Hardy (1990) zaimplementował strategię globalnej alokacji aktywów prognozując akcje amerykańskie oraz akcje pięciu innych giełd. Jego model regresji, w którym użył ośmiomiesięczny okres estymacji do wygenerowania prognoz, sprawdził się lepiej niż strategię pasywną. Według wiedzy autora, do tej pory nie przeprowadzono za pomocą modelu probitowego badania zależności między spreadami Złoto – S&P 500, Złoto – Dolar / Jen, S&P 500 – Dolar / Jen. Będzie to pierwsze opracowanie w którym przeprowadzi się analizę dotyczącą rotacyjnej alokacji między wyżej wymienione instrumenty. Dodatkowo portfel złożony z tych

instrumentów miał zapewniać niewielkie wahania w okresie inwestycyjnym. Autor czerpał wiedzę z opracowania Baur i Lucey (2009), w którym to autorzy są zdania, że złoto jest tzw. bezpiecznym aktywem w portfelu. Ich wyniki wskazują, że złoto jest naturalną przeciwwagą dla rynku akcji w burzliwych czasach na rynkach finansowych.

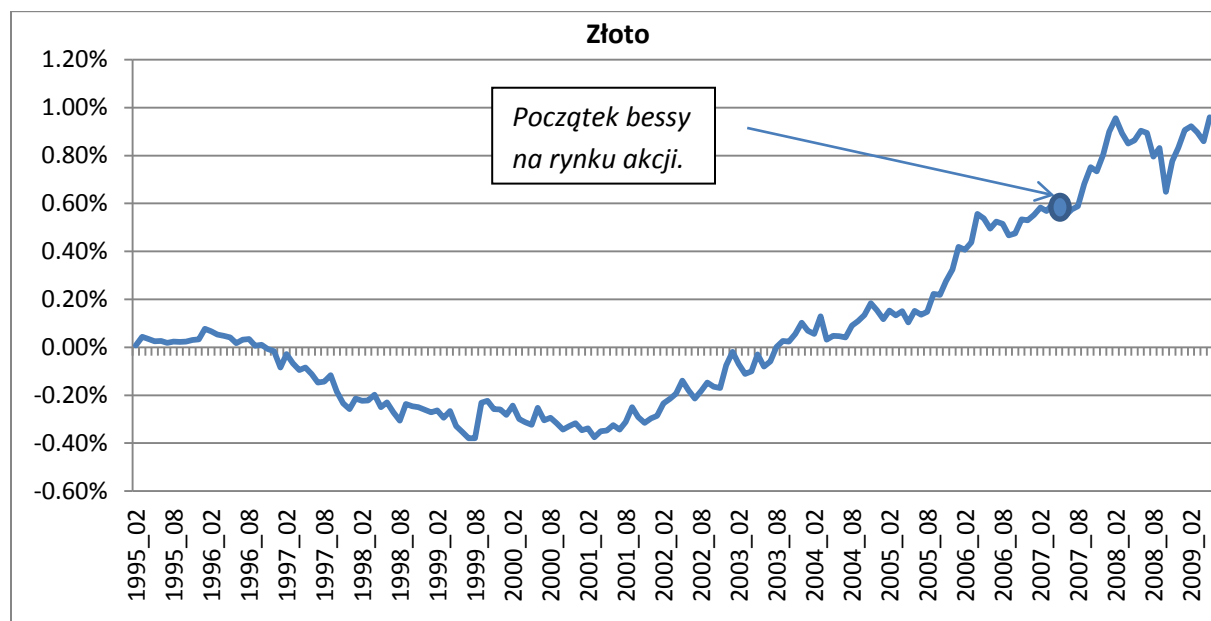
5.2. Analiza powiązań między Złotem, Dolar / Jen i S&P 500.

Mówiąc o inwestowaniu na rynkach towarowych jako alternatywie w stosunku do inwestowania w akcje, myślimy na ogół o rynku złota. Uważa się go za najbezpieczniejszą lokatę w czasach politycznych lub finansowych wstrząsów. W chwilach niepewności na rynku akcji inwestorzy zwracają się ku rynkowi złota lub akcjom kopalni złota. Oczywiście złoto może być dobrą alternatywą dla akcji w okresach wysokiej inflacji (jak na przykład w latach siedemdziesiątych), ale na pewno nie jest atrakcyjne, gdy inflacja jest niska (tak jak przez większą część lat osiemdziesiątych). Znaczenie złota jest bardzo duże ze względu na silną odwrotną zależność z dolarem, tendencję do wyprzedzania zwrotów na pozostałych rynkach towarowych oraz bezpieczeństwo, jakie daje w czasach zamętu. Aby zobrazować te teorie przedstawiono wykres 13, na którym przedstawiono zachowanie się kursu złota oraz wykresy 14 i 15 na których można zauważyć zachowanie się wzajemnych relacji między złotem, a indeksem S&P 500 oraz złotem i Dolar / Jen.

Charakterystyka zachowań spreadu na wykresie 14 sprawia, że można przypuszczać, iż występuje autokorelacja stóp zwrotu. Wydaje się zasadne zastosowanie w tej sytuacji strategii momentum. Rozważania te, będą kontynuowane w dalszej części opracowania.

Na wykresie 15 można zaobserwować trend wzrostowy spreadu między Złotem a Dolar / Jen. Zwrócić uwagę należy na podwójne dno między 2001 a 2002 rokiem, które było zwiastunem późniejszej hossy na rynku akcji. Można uznać, że spread ten ma w sobie pewne wartości prognostyczny. Relacja między złotem a walutą dolar / jen nie jest jednoznaczna. Z jednej strony złoto jest wyceniane w dolarach amerykańskich, więc rosnące ceny złota powinny pociągać za sobą spadek kursu dolara, z drugiej jednak strony rosnące ceny złota często bywają zapowiedzą spadku notowań na rynku akcji, gdyż inwestorzy uciekając od ryzykownych aktywów zajmują długą pozycję na złocie, traktując je jako „oazę spokoju”. Natomiast japońska waluta jest silnie skorelowana z rynkami surowców. Japonia jako importer netto surowców silnie reaguje na zmiany cen surowców. Zazwyczaj, gdy ceny surowców rosną, jen spada. Wzrasta wówczas koszt pozyskania surowców dla kraju kwitnącej wiśni.

Wykres 13. Przedstawia skumulowane stopy zwrotu w ujęciu procentowym dla złota.




Źródło: Opracowanie własne.

Dodatkowo waluta dolar / jen ma charakterystykę, która sprawia że w pewnych okresach instrument ten posiada dodatnie stopy zwrotu w czasach bessy na giełdzie. Podobnie reagującym instrumentem na załamanie na rynku akcji jest niewątpliwie złoto. Wzrost dolara jest korzystny dla akcji, gdyż stanowi czynnik deflacyjny i powoduje spadek stóp procentowych. Z kolei zniżający dolar pobudza inflację przyczyniając się do wzrostu stóp procentowych, i tym samym pociąga za sobą w dół rynki akcji²⁰. Jen ma nieco odmienną charakterystykę niż dolar. Japońska waluta ma tendencję do osłabiania się w sytuacji wzrostów na rynku akcji. Ma to związek, z faktem, że gospodarka japońska jest silnie uzależniona od eksportu i słaby jen powoduje większe wpływy ze sprzedaży towarów na granicę.


²⁰ Murphy J.: Międzyrynkowa analiza techniczna, WigPress, Warszawa, 1998, s. 121

Wykres 14. Spread w ujęciu procentowym między Złotem, a indeksem S&P 500.



Źródło: Opracowanie własne.

Wykres 15. Spread w ujęciu procentowym między Złotem, a Dolar / Jen.




Źródło: Opracowanie własne.

W sytuacji, gdy następuje spadek na globalnych rynkach akcji, jen, i w mniejszym stopniu również frank szwajcarski, ma tendencję do wzrostu wartości w porównaniu do innych walut, podczas gdy na przykład dolar australijski i nowozelandzki ma tendencję do spadku w stosunku do innych walut. Wykres 16 i 17 przedstawiają kolejno skumulowane stopy zwrotu w ujęciu procentowym dla indeksu S&P 500 oraz waluty Dolar / Jen.

Z pobieżnej analizy wykresów 16 i 17 można wysunąć wniosek, że kurs Dolar / Jen zachowuje się bardziej stacjonarnie, niż kurs indeksu S&P 500. Można zauważyć, że Dolar / Jen począwszy od szczytu w 1998 roku znajduje się w trendzie spadkowym, jednak korekty od tego trendu są wyraziste i długo trwają.

Wykres 16. Skumulowane stopy zwrotu w ujęciu procentowym dla indeksu S&P 500.




Źródło: Opracowanie własne.

Następnie porównując spread między tymi instrumentami, wykres 18, wyraźnie widać, że kształt ma zbliżony do kurs indeksu S&P 500. Występują jednak różnice. Spread S&P500 - USDjpy zareagował z opóźnieniem na początek bessy na rynku akcji w połowie 2007 roku.


Powyższe rozważania nad zależnościami pomiędzy złotem, indeksem S&P500 oraz waluta dolar / jen miały za zadanie wprowadzić w tematykę badania empirycznego, w którym zostanie wykorzystany model probitowy.

Wykres 17. Skumulowane stopy zwrotu w ujęciu procentowym dla waluty Dolar / Jen.



Źródło: Opracowanie własne.

Wykres 18. Spread między indeksem S&P 500 a Dolar / Jen.



Źródło: Opracowanie własne.

5.3. Cel pracy, hipotezy badawcze

W rozdziale tym dokonano badania w celu odpowiedzi na pytanie czy krótkoterminowe odchylenia w stopach zwrotu na spreadzie między Złoto – S&P 500, Złoto – Dolar/Jen oraz S&P 500 – Dolar/Jen mogą być lepiej wyjaśniane przez następujące metody:

- ✓ model probitowy
- ✓ strategie momentum²¹
- ✓ strategia pasywną²²

W toku prac nad tym obszarem badawczym największym dylematem dla autora było znalezienie odpowiedniego benchmarku dla strategii dla poszczególnych spreadów. Ostatecznie zdecydowano się na odniesienie się do strategii pasywnej polegającą na zajęciu pozycji długiej na obu instrumentach wchodzących w skład danego spreadu. Jako drugi benchmarku wybrano strategię pasywną polegającą na utrzymywaniu długiej pozycji na indeksie S&P500.

Autor w poszukiwaniu metod, które „lepiej wyjaśniają” odchylenia na spreadzie Złoto – S&P 500, Złoto – Dolar/Jen oraz S&P 500 – Dolar/Jen, szuka takich modeli, za pomocą, których portfel inwestycyjny posiada najwyższą wartość wskaźnika stopa zwrotu / odchylenie standardowe. W tym celu autor zbuduje modele probitowe dla spreadów:

- Złoto – S&P 500,
- Złoto – Dolar/Jen,
- S&P 500 – Dolar/Jen.

Prognozy z modeli dla badanych spreadów dostarcza wagi dla instrumentów w portfelu. Na podstawie tych wag skonstruowany zostanie globalny portfel dla badanych instrumentów.

Dodatkowo autor odpowie na pytania:

²¹ Strategia momentum polega na wyborze (zakupie) do portfela instrumentu, który w poprzednim miesiącu uzyskał niższą stopę zwrotu. W ten sposób w każdym z miesięcy portfel będzie się składał albo w 100% z kontraktu na Złoto albo w 100% z kontraktu na S&P 500 albo z waluty Dolar/Jen

²² Strategia pasywna polega na zajęciu długiej pozycji i jednoczesnym skonstruowaniu portfela składającego się w 1/3 z kontraktu na złoto, w 1/3 z kontraktu na indeks S&P500 oraz w 1/3 z waluty Dolar/Jen. Skład portfela jest stały przez cały okres.

- Które z kryteriów dobroci modeli probitowych najlepiej wyjaśnia odchylenia na spreadzie Złoto – S&P 500, Złoto – Dolar/Jen oraz S&P 500 – Dolar/Jen.

Jako kryteria dobroci modelu probitowego autor wyróżnił:

- Test ilorazu wiarygodności
 - Iloraz szans wyznaczony na podstawie tabeli trafności klasyfikacji przypadków,
 - Kryterium Akaike’a,
 - Absolutny błąd prognozy,
 - Dodatkowym kryterium był tzw. ranking łączny dla wyżej wymienionych kryteriów, o którym mowa będzie w dalszej części pracy.
- Czy stosowanie dywersyfikacji portfela²³ polepsza relację stopa zwrotu / odchylenie standardowe.
- Jak przedstawiają się wyniki procesu alokacji z perspektywy polskiego inwestora.
- Czy dla poszczególnych spreadów można wyróżnić zmienne w poszczególnych modelach, które w istotny sposób prognozują jego kierunek.
- Czy istotność zmiennych z testu Simsa pokrywa się z istotnością tej samej zmiennej w wybranych modelach?
- Czy stabilne są relacje oparte na jednej zmiennej mającej średnio największy wpływ na dany spread według wybranych modeli ?

5.4. Metodologia i wyniki badań.

Dokonano wyboru zmiennych objaśniających opierając się na zmiennych, których użyto w rozdziale 3.

Wyselekcjonowane zmienne objaśniające poddano testowi Simsa na zbadanie istnienia związków przyczynowych między zmienną objaśnianą, a opóźnionymi zmiennymi objaśniającymi.

²³ Jako wyżej wymienioną dywersyfikację autor rozumie lokowanie kapitału we wszystkie instrumenty według wag dostarczonych przez model probitowy, w odróżnieniu od lokowania kapitału tylko w jeden instrument.

Testowanie zmiennych podzielono na 3 grupy, które dotyczyły badania istotności zmiennych objaśniających względem przyszłych wartości spreadu:

- Złoto – S&P 500,
- Złoto – Dolar/Jen
- S&P 500 – Dolar/Jen

Tabela 24 przedstawia ranking zmiennych objaśniających dla spreadu Złoto – S&P500 oraz wartości p dla poszczególnych zmiennych i ich opóźnień.

Tabela 25 przedstawia ranking zmiennych objaśniających dla spreadu Złoto – Dolar / Jen oraz wartości p dla poszczególnych zmiennych i ich opóźnień.

Tabela 26 przedstawia ranking zmiennych objaśniających dla spreadu S&P500 - Dolar / Jen oraz wartości p dla poszczególnych zmiennych i ich opóźnień.

Następnie przystąpiono do estymacji modeli ekonometrycznych prognozujących zmianę spreadu między Złoto – S&P 500, Złoto – Dolar/Jen oraz S&P 500 – Dolar/Jen. Do tego celu użyto model probitowy.

Głównym celem estymacji modeli było znalezienie po jednym modelu, który optymalizuje następujące kryteria:

- Test ilorazu wiarygodności
- Iloraz szans wyznaczony na podstawie tabeli trafności klasyfikacji przypadków,
- Kryterium Akaike'a,
- Absolutny błąd prognozy.

Następnie dokonano estymacji modeli w oparciu o dwie metody krokowe konstrukcji modelu probitowego:

- Algorytm regresji krokowej postępującej oraz algorytm regresji krokowej wstecznej.

Tabela 24. Ranking testu Simsa dla spreadu Złoto – S&P500 według wartości p w ujęciu procentowym.

Numer	Zmienna objaśniająca	Wartość p
1	PPrzUS_1	0,0043
2	PPrzUS_3	0,0052
3	Soja_3	0,011
4	InfUs_2	0,0129
5	SP500_SP400_1	0,0156
6	PPrzUS_2	0,0186
7	OblUs30_Zloto_2	0,0245
8	Ryż_2	0,0313
9	PrPrzUs_InfUs_3	0,0329
10	SP400_1	0,0341
11	M1_Eur_1	0,036
12	Brent_SP500_1	0,0395
13	Zloto_Brent_1	0,0465
14	PrPrzUs_InfUs_1	0,0497
15	M2Us_3	0,0552
16	Pallad_1	0,0572
17	OblUs10_PkbUs_3	0,0686
18	SP500_SP400_2	0,0744
19	Ryż_3	0,0878
20	SP100_SP400_1	0,0893
21	OblBund_2	0,0902
22	Pallad_3	0,0927
23	Miedź_3	0,0948
24	OblBund_2	0,0971

Źródło: Opracowanie własne.

Tabela 25. Ranking testu Simsa dla spreadu Złoto – Dolar / Jen według wartości p w ujęciu procentowym.

Numer	Zmienna objaśniająca	Wartość p
1	Miedź_3	0,0002
2	SP400_2	0,0039
3	SP500_1	0,0097
4	Usdpln_SP500_2	0,0108
5	SP100_1	0,0144
6	ISM_SP500_2	0,0196
7	Soja_3	0,0217
8	Ryż_2	0,0263
9	M2Us_2	0,0518
10	Złoto_SP100_2	0,0558
11	Bund_Bobl_2	0,056
12	Brent_SP500_1	0,0583
13	Miedź_2	0,0665
14	Zloto_Brent_1	0,0748
15	M2_Eur_1	0,081
16	USDpln_Brent_3	0,0934
17	d_ISM_3	0,0937
18	OblUs30_Zloto_2	0,0965

Źródło: Opracowanie własne.

Tabela 26. Ranking testu Simsa dla spreadu S&P500 - Dolar / Jen według wartości p w ujęciu procentowym.

Numer	Zmienna objaśniająca	Wartość p
1	SP400_2	0,0008
2	PPrzUS_1	0,0016
3	PrPrzUs_Inf_1	0,0028
4	SP500_SP400_1	0,0056
5	Usdpln_SP500_2	0,0084
6	SP500_2	0,0283
7	Zbydło	0,0387
8	Brent_3	0,0389
9	Zloto_Brent_3	0,0419
10	USDpln_Brent_3	0,0475
11	SP100_2	0,0608
12	ISM_SP500_2	0,0639
13	d_ISM_1	0,0705
14	PPrzUS_3	0,0802
15	Usdpln_2	0,0822

Zródło: Opracowanie własne

5.4.1. Estymacja modeli dla spreadu Złoto – S&P500.

Model probitowy dla spreadu Złoto – S&P500 ma postać następującą:

$$P(Y_{t+1} = 1|x) = P(y=1|X_t)$$

gdzie,

X_t – zmienne objaśniające

$Y_{t+1} = 1$, jeśli różnica w ujęciu procentowym między Złotem a SP 500 będzie dodatnia w okresie jednego miesiąca naprzód względem zmiennych objaśniających, w przeciwnym wypadku $Y_{t+1} = 0$.

Ostatecznie dla spreadu Złoto – S&P500 stworzono 57 modeli. Tabela 27, 28, 29 przedstawia modele wraz z wartościami kryterii, które były brane pod uwagę przy selekcji modeli. Sposób identyfikacji modeli w tabelach 27 i 28 należy czytać analogicznie jak w rozdziale 3.4. w tabelach 8, 9. Natomiast modele w tabeli 29 przedstawiają estymacje modeli probitowych na podstawie metody regresji krokowej wstecznej. Numer po kropce w kolejnych modelach oznacza liczbę kolejnych estymacji metodą regresji krokowej wstecznej, czyli im mniejszy numer po kropce tym więcej usunięto zmiennych najmniej istotnych. Po każdej takiej estymacji najmniej istotna zmienna została usunięta.

Tabela 27. Poszczególne modele probitowe i ich charakterystyki dla spreadu Złoto – S&P500.

Model	Zmienne	Najmniej istotna zmienna	Liczba przypadków poprawnej predykcji	Test ilorazu wiarygodności [wartość p]	Kryt. inform. Akaike'a	Średni błąd absolutny
1	PPrzUS_1		62,70%	0,1834	111,9212	0,4789
2	PPrzUS_3	<i>PPrzUS_3</i>	60,50%	0,3438	110,6474	0,45436
3	Soja_3	<i>PPrzUS_1</i>	59,30%	0,374	108,039	0,46553
4	InfUs_2	<i>PPrzUS_3</i>	67,90%	0,0671	108,0138	0,41823
5	SP500_SP400_1	<i>PPrzUS_3</i>	65,40%	0,0572	108,0631	0,40835
6	PPrzUS_2	<i>PPrzUS_2</i>	70,40%	0,0801	109,5017	0,40479
7	OblUs30_Zloto_2	<i>PPrzUS_3</i>	70,40%	0,0135	105,0949	0,37488
8	Ryz_2	<i>Ryz_2</i>	74,10%	0,0216	106,8385	0,373
9	PrPrzUs_InfUs_3	<i>PPrzUS_2</i>	70,40%	0,0235	107,5777	0,36754
10	SP400_1	<i>SP400_1</i>	70,40%	0,0377	109,5721	0,36759
11	M1_Eur_1	<i>SP400_1</i>	75,30%	0,0412	110,4644	0,36285
12	Brent_SP500_1	<i>SP400_1</i>	77,80%	0,0543	112,0385	0,36115
13	Zloto_Brent_1	<i>PPrzUS_3</i>	72,80%	0,0223	109,6707	0,34001
14	PrPrzUs_InfUs_1	<i>SP500_SP400_1</i>	76,50%	0,0296	111,248	0,3377
15	M2Us_3	<i>PPrzUS_3</i>	77,80%	0,0179	110,1451	0,32097
16	Pallad_1	<i>PPrzUS_3</i>	77,80%	0,0253	111,97	0,32023

c.d. Tabela 27.

17	OblUs10_PkbUs_3	SP500_SP400_1	79,00%	0,02	112,14	0,31186
18	SP500_SP400_2	PPrzUS_3	80,20%	0,02	112,18	0,30193
19	Ryz_3	PPrzUS_3	81,50%	0,03	114,04	0,30
20	SP100_SP400_1	PPrzUS_3	79,00%	0,03	115,34	0,30
21	OblBund_2	PPrzUS_3	81,50%	0,03	115,75	0,29
22	Pallad_3	PPrzUS_3	79,00%	0,04	117,69	0,2939
23	Miedź_3	PPrzUS_3	76,50%	0,03	116,87	0,2847
24	OblBobl_2	PPrzUS_3	76,50%	0,03	118,50	0,28272

Źródło: Opracowanie własne.

Tabela 28. Poszczególne modele probitowe, z których usunięto najmniej istotną zmienną dla spreadu Złoto – S&P500.

Model	Najmniej istotna zmienna	Liczba przypadków poprawnej predykcji	Test ilorazu wiarygodności [wartość p]	Kryt. inform. Akaike'a	Średni błąd absolutny
3a	PPrzUS_1	64,20%	0,0526	106,8944	0,43434
4a	PPrzUS_3	65,40%	0,0452	106,7453	0,42205
5a	PPrzUS_3	67,90%	0,0421	106,8815	0,41286
6a	PPrzUS_2	65,40%	0,0572	108,0631	0,40835
7a	PPrzUS_3	69,10%	0,0091	103,7461	0,37888
8a	Ryz_2	74,10%	0,0216	106,8385	0,373
9a	PPrzUS_2	70,40%	0,0162	106,0174	0,36929
10a	SP400_1	70,40%	0,0377	109,5721	0,36759
11a	SP400_1	75,30%	0,0267	108,505	0,36276
12a	SP400_1	77,80%	0,0387	110,2615	0,36151
13a	PPrzUS_3	74,10%	0,0147	107,749	0,34046
14a	SP500_SP400_1	76,50%	0,0197	109,2545	0,33785
15a	PPrzUS_3	77,80%	0,0117	108,1454	0,32097

c.d. Tabela 28.

16a	PPrzUS_3	77,80%	0,017	109,9765	0,32025
17a	SP500_SP400_1	79,00%	0,015	110,1517	0,3119
18a	PPrzUS_3	80,20%	0,0127	110,1901	0,30202
19a	PPrzUS_3	81,50%	0,0179	112,0405	0,30125
20a	PPrzUS_3	79,00%	0,0214	113,3448	0,29822
21a	PPrzUS_3	81,50%	0,0199	113,7467	0,29409
22a	PPrzUS_3	79,00%	0,0276	115,6949	0,29392
23a	PPrzUS_3	76,50%	0,0188	114,8765	0,28461
24a	PPrzUS_3	76,50%	0,0237	116,4976	0,28271

Źródło: Opracowanie własne.

Tabela 29. Modeli probitowe na podstawie metody regresji krokowej wstecznej dla spreadu
Złoto – S&P500.

Model	Liczba przypadków poprawnej predykcji	Test ilorazu wiarygodności [wartość p]	Kryt. inform. Akaike'a	Średni błąd absolutny
1.6	80,20%	0,0058	108,6923	0,28354
1.7	80,20%	0,0056	107,9759	0,28896
1.8	81,50%	0,0037	106,0447	0,28929
1.9	76,50%	0,0025	104,3875	0,29115
1.14	76,50%	0,002	101,4588	0,3193
1.10	75,30%	0,0019	102,9468	0,2929
1.15	76,50%	0,0019	100,9039	0,32313
1.12	79,00%	0,0018	101,963	0,30343
1.17	74,10%	0,0018	100,0868	0,3393
1.11	76,50%	0,0017	102,1454	0,29642
1.16	77,80%	0,0016	100,2019	0,33072

Źródło: Opracowanie własne.

Następnie stworzono rankingi modeli według wyżej omówionych kryteriów dobroci modelu.

W ten sposób powstały rankingi według następujących kryteriów:

- Ranking 1 - Liczba przypadków poprawnej predykcji
- Ranking 2 - Test ilorazu wiarygodności
- Ranking 3 - Kryt. inform. Akaike'a
- Ranking 4 - Średni błąd absolutny

Modele były oceniane, tabela 30, w taki sposób, że punkty w rankingu były przydzielane według reguły:

$$(x-k+1),$$

gdzie x – ilość modeli w rankingu, k – miejsce modelu w rankingu.

Tabela 30. Modele probitowe wg. poszczególnych kryteriów dobroci modelu dla spreadu Złoto – S&P500

Model	Liczba przypadków poprawnej predykcji	Model	Test ilorazu wiarygodności [wartość p]	Model	Kryt. inform. Akaike'a	Model	Średni błąd absolutny
20	81,50%	1.16	0,0016	1.16	100,0019	24a	0,28271
22	81,50%	1.11	0,0017	1.17	100,0868	25	0,28272
19a	81,50%	1.12	0,0018	1.15	100,9039	1.6	0,28354
21a	81,50%	1.17	0,0018	1.14	101,4588	23a	0,28461
8.8	81,50%	1.10	0,0019	1.12	101,963	24	0,2847
19	80,20%	1.15	0,0019	1.11	102,1454	1.7	0,28896
18a	80,20%	1.14	0,002	1.10	102,9468	1.8	0,28929
6.6	80,20%	1.9	0,0025	7a	103,7461	1.9	0,29115
7.7	80,20%	1.8	0,0037	1.9	104,3875	1.10	0,2929
18	79,00%	1.7	0,0056	7	105,0949	23	0,2939
21	79,00%	1.6	0,0058	9a	106,0174	22a	0,29392
23	79,00%	7a	0,0091	1.8	106,0447	22	0,29
12.12	79,00%	15a	0,0117	4a	106,7453	21a	0,29409

c.d. Tabela 30.

17a	79,00%	18a	0,0127	8	106,8385	1.11	0,29642
20a	79,00%	7	0,0135	8a	106,8385	20a	0,29822
22a	79,00%	13a	0,0147	5a	106,8815	21	0,30
12	77,80%	17a	0,015	3a	106,8944	19a	0,30125
15	77,80%	9a	0,0162	9	107,5777	20	0,30
16	77,80%	16a	0,017	13a	107,749	19	0,30193
12a	77,80%	15	0,0179	1.7	107,9759	18a	0,30202
15a	77,80%	19a	0,0179	4	108,0138	1.12	0,30343
16.16	77,80%	19	0,02	3	108,039	18	0,31186
16a	77,80%	23a	0,0188	5	108,0631	17a	0,3119
14	76,50%	14a	0,0197	6a	108,0631	1.14	0,3193
24	76,50%	21a	0,0199	15a	108,1454	16	0,32023
25	76,50%	20a	0,0214	11a	108,505	16a	0,32025
11.11	76,50%	8	0,0216	6.6	108,6923	15	0,32097
14.14	76,50%	8a	0,0216	14a	109,2545	15a	0,32097
14a	76,50%	18	0,02	6	109,5017	1.15	0,32313
15.15	76,50%	13	0,0223	10	109,5721	1.16	0,33072
23a	76,50%	9	0,0235	10a	109,5721	14	0,3377
24a	76,50%	24a	0,0237	13	109,6707	14a	0,33785
9.9	76,50%	16	0,0253	16a	109,9765	1.17	0,3393
11	75,30%	20	0,03	15	110,1451	13	0,34001
10.10	75,30%	24	0,03	17a	110,1517	13a	0,34046
11a	75,30%	11a	0,0267	18a	110,1901	12	0,36115
8	74,10%	22a	0,0276	12a	110,2615	12a	0,36151
13a	74,10%	22	0,03	11	110,4644	11a	0,36276
17.17	74,10%	14	0,0296	2	110,6474	11	0,36285
8a	74,10%	21	0,03	14	111,248	9	0,36754
13	72,80%	25	0,03	1	111,9212	10	0,36759

c.d. Tabela 30.

6	70,40%	10	0,0377	16	111,97	10a	0,36759
7	70,40%	10a	0,0377	12	112,0385	9a	0,36929
9	70,40%	23	0,04	19a	112,0405	8	0,373
10	70,40%	12a	0,0387	18	112,14	8a	0,373
10a	70,40%	11	0,0412	19	112,18	7	0,37488
9a	70,40%	5a	0,0421	20a	113,3448	7a	0,37888
7a	69,10%	4a	0,0452	21a	113,7467	6	0,40479
4	67,90%	3a	0,0526	20	114,04	5	0,40835
5a	67,90%	12	0,0543	23a	114,8765	6a	0,40835
5	65,40%	5	0,0572	21	115,34	5a	0,41286
4a	65,40%	6a	0,0572	22a	115,6949	4	0,41823
6a	65,40%	4	0,0671	22	115,75	4a	0,42205
3a	64,20%	6	0,0801	24a	116,4976	3a	0,43434
1	62,70%	1	0,1834	24	116,87	2	0,45436
2	60,50%	2	0,3438	23	117,69	3	0,46553
3	59,30%	3	0,374	25	118,50	1	0,4789

Opracowanie: Źródło własne.

Tabela 31. Ranking łączny modeli probitowych dla spreadu Złoto – S&P500

Model	Liczba przypadków poprawnej predykcji	Test ilorazu wiarygodności [wartość p]	Kryt. inform. Akaike'a	Średni błąd absolutny	Punkty
1.8	53	49	46	51	199
1.12	42	55	53	37	187
1.7	49	48	38	52	187
1.6	50	47	31	55	183
1.11	27	56	52	44	179

c.d. Tabela 31.

1.9	28	50	49	50	177
1.16	35	57	56	28	176
1.10	22	53	51	49	175
1.14	26	51	54	34	165
1.15	25	52	55	29	161
18a	51	44	22	38	155
1.17	18	54	57	25	154
19a	55	37	14	41	147
15a	37	45	33	30	145
17a	45	41	23	35	144
21a	54	33	10	45	142
19	52	36	12	39	139
15	40	38	24	31	133
16a	36	39	25	32	132
20	57	24	9	40	130
20a	44	32	11	43	130
22	56	20	5	46	127
23a	30	35	8	54	127
18	48	29	13	36	126
13a	20	42	39	23	124
14a	31	34	30	26	121
7	15	43	48	12	118
22a	43	21	6	47	117
7a	10	46	50	11	117
24a	29	26	4	57	116
21	47	18	7	42	114
16	39	25	16	33	113
9a	11	40	47	15	113

c.d. Tabela 31.

24	33	23	3	53	112
8	21	31	44	14	110
23	46	14	2	48	110
25	32	17	1	56	106
8a	19	30	43	13	105
9	14	27	40	18	99
14	34	19	18	27	98
11a	23	22	32	20	97
13	17	28	26	24	95
12a	38	13	21	21	93
12	41	8	15	22	86
11	24	12	20	19	75
10	13	16	28	17	74
10a	12	15	27	16	70
5a	8	11	42	7	68
4a	6	10	45	5	66
6	16	4	29	10	59
5	7	7	35	9	58
3a	4	9	41	4	58
4	9	5	37	6	57
6a	5	6	34	8	53
3	1	1	36	2	40
2	2	2	19	3	26
1	3	3	17	1	24

Opracowanie: Źródło własne.

Po analizie dopasowań wszystkich modeli wybrano 3 modele.

- Model 1 - model 1.8 był preferowany zarówno pod względem liczba przypadków poprawnej predykcji, jak i rankingu łącznego ,

- Model 2 - model 1.16 był preferowany zarówno pod względem testu ilorazu wiarygodności, jak i Kryterium informacyjnym Akaike'a ,
- Model 3 - model 24a był preferowany pod względem średniego błędu absolutnego. Dodatkowo skonstruowano model 4, dla którego wagi dostarczyła średnia z wag modelu 1, modelu 2 i modelu 3.

Oszacowania wybranych modeli przedstawiają się następująco:

Model 1

Estymacja Probit, wykorzystane obserwacje 3/1995 – 12/2001

Zmienna zależna: Złoto – S&P500

	współczynnik	błąd standardowy	t-Studenta	wartość p	
const	0,494085	0,54058	0,914	0,3607	
PPrzUS_1	-194,219	118,463	-1,639	0,1011	
Soja_3	4,48518	3,76147	1,192	0,2331	
PPrzUS_2	-34,0577	39,0236	-0,8727	0,3828	
OblUs30_Zloto_2	16,603	6,19896	2,678	0,0074	***
Ryz_2	-4,51024	2,75799	-1,635	0,102	
PrPrzUs_InfUs_3	-0,562302	0,36034	-1,56	0,1187	
SP400_1	-14,3343	6,40707	-2,237	0,0253	**
M1_Eur_1	24,4271	26,6925	0,9151	0,3601	
Brent_SP500_1	12,9202	6,3173	2,045	0,0408	**
Zloto_Brent_1	-13,6452	6,07812	-2,245	0,0248	**
PrPrzUs_InfUs_1	1,47742	1,10584	1,336	0,1815	
M2Us_3	-154,309	79,9423	-1,93	0,0536	*
OblUs10_PkbUs_3	0,233316	0,15432	1,512	0,1306	
SP500_SP400_2	-12,5372	7,86699	-1,594	0,111	
OblBund_2	33,6019	31,5263	1,066	0,2865	
Mied_3	-5,38007	3,34569	-1,608	0,1078	
OblBunda	-25,9821	44,2952	-0,5866	0,5575	

c.d. Model 1

Logarytm wiarygodności -35,02236 Kryt. inform. Akaike'a 106,0447

Liczba przypadków 'poprawnej predykcji' = 66 (81,5%)

Test ilorazu wiarygodności: Chi-kwadrat(17) = 36,738 [0,0037]

Model 2

Estymacja Probit, wykorzystane obserwacje 3/1995 – 12/2001

Zmienna zależna: Złoto – S&P500

		błąd			
	współczynnik	standardowy	t-Studenta	wartość p	
const	0,57005	0,42466	1,342	0,1795	
PPrzUS_1	-245,722	97,3062	-2,525	0,0116	**
OblUs30_Zloto_2	10,239	4,01111	2,553	0,0107	**
Ryz_2	-2,93765	2,17716	-1,349	0,1772	
SP400_1	-10,223	5,01247	-2,04	0,0414	**
Brent_SP500_1	7,21092	4,72771	1,525	0,1272	
Zloto_Brent_1	-8,54979	4,62708	-1,848	0,0646	*
PrPrzUs_InfUs_1	1,73563	0,90671	1,914	0,0556	*
M2Us_3	-105,624	67,5553	-1,564	0,1179	
SP500_SP400_2	-14,5771	6,93639	-2,102	0,0356	**

Logarytm wiarygodności -40,10095 Kryt. inform. Akaike'a 100,2019

Liczba przypadków 'poprawnej predykcji' = 63 (77,8%)

Test ilorazu wiarygodności: Chi-kwadrat(9) = 26,5808 [0,0016]

Model 3

Estymacja Probit, wykorzystane obserwacje 3/1995 – 12/2001

Zmienna zależna: Złoto – S&P500

	współczynnik	błąd standardowy	t- Studenta	wartość p	
const	0,528142	0,57572	0,9174	0,359	
PPrzUS_1	-204,984	132,691	-1,545	0,1224	
Soja_3	3,37941	3,88564	0,8697	0,3845	
InfUs_2	-0,237417	1,04136	-0,228	0,8197	
SP500_SP400_1	-9,65714	17,9134	-0,5391	0,5898	
PPrzUS_2	-33,0568	41,3489	-0,7995	0,424	
OblUs30_Zloto_2	18,1503	6,97657	2,602	0,0093	***
Ryz_2	-4,13024	3,20389	-1,289	0,1974	
PrPrzUs_InfUs_3	-0,511215	0,3858	-1,325	0,1851	
SP400_1	-19,4378	11,3191	-1,717	0,0859	*
M1_Eur_1	25,5024	27,6105	0,9237	0,3557	
Brent_SP500_1	17,6308	10,0185	1,76	0,0784	*
Zloto_Brent_1	-17,7087	8,89857	-1,99	0,0466	**
PrPrzUs_InfUs_1	1,55693	1,27366	1,222	0,2216	
M2Us_3	-150,521	84,6887	-1,777	0,0755	*
Pallad_1	0,189914	2,3162	0,08199	0,9347	
OblUs10_PkbUs_3	0,215247	0,1624	1,325	0,185	
SP500_SP400_2	-12,9876	8,16382	-1,591	0,1116	
Ry_3	0,431649	3,37781	0,1278	0,8983	
SP100_SP400_1	4,53955	10,0726	0,4507	0,6522	
OblBund_2	36,777	32,6781	1,125	0,2604	
Pallad_3	-0,557758	2,18448	-0,2553	0,7985	
Miedź_3	-5,90652	3,61882	-1,632	0,1026	
OblBobl_2	-28,8245	46,7421	-0,6167	0,5375	

c.d. Model 3.

Logarytm wiarygodności -34,24878 Kryt. inform. Akaike'a 116,4976

Liczba przypadków 'poprawnej predykcji' = 62 (76,5%)

Test ilorazu wiarygodności: Chi-kwadrat(23) = 38,2851 [0,0237]

5.4.2. Estymacja modeli dla spreadu Złoto – Dolar / Jen

Model probitowy dla spreadu Złoto – Dolar / Jen ma postać następującą:

$$P(Y_{t+1} = 1|x) = P(y=1|X_t)$$

gdzie,

X_t – zmienne objaśniające

$Y_{t+1} = 1$, jeśli różnica w ujęciu procentowym między Złotem a Dolar / Jen będzie dodatnia w okresie jednego miesiąca naprzód względem zmiennych objaśniających, w przeciwnym wypadku $Y_{t+1} = 0$.

Ostatecznie dla spreadu Złoto – Dolar / Jen stworzono 47 modeli. Tabela 32, 33 i 34 przedstawia modele wraz z wartościami kryterii, które były brane pod uwagę przy selekcji modeli. Sposób identyfikacji modeli w tabelach 32 i 33 należy czytać analogicznie jak w rozdziale 3.4. w tabelach 8 i 9. Natomiast modele w tabeli 34 przedstawiają estymacje modeli probitowych na podstawie metody regresji krokowej wstecznej. Numer po kropce w kolejnych modelach oznacza liczbę kolejnych estymacji metodą regresji krokowej wstecznej; im mniejszy numer po kropce tym więcej usunięto zmiennych najmniej istotnych. Po każdej takiej estymacji najmniej istotna zmienna została usunięta.

Następnie stworzono rankingi modeli według wyżej omawianych kryteria dobroci modelu. W ten sposób powstały rankingi według następujących kryteriów:

- Ranking 1 - Liczba przypadków poprawnej predykcji
- Ranking 2 - Test ilorazu wiarygodności
- Ranking 3 - Kryt. inform. Akaike'a
- Ranking 4 - Średni błąd absolutny

Tabela 32. Poszczególne modele probitowe i ich charakterystyki dla spreadu Złoto –
Dolar / Jen

Model	Zmienne	Najmniej istotna zmienna	Liczba przypadków poprawnej predykcji	Test ilorazu wiarygodności [wartość p]	Kryt. inform. Akaike'a	Średni błąd absolutny
1	Miedź_3		0,63	0,0356	107,3741	0,44718
2	SP400_2	<i>SP400_2</i>	0,65	0,0540	107,9542	0,43882
3	SP500_1	<i>SP400_2</i>	0,65	0,0444	107,7111	0,42709
4	Usdpln_SP500_2	<i>Usdpln_SP500_2</i>	0,67	0,0870	109,6642	0,42693
5	SP100_1	<i>SP100_1</i>	0,68	0,1476	111,6314	0,42681
6	ISM_SP500_2	<i>ISM_SP500_2</i>	0,68	0,2258	113,6193	0,42676
7	Soja_3	<i>ISM_SP500_2</i>	0,70	0,1659	113,3684	0,41494
8	Ryż_2	<i>ISM_SP500_2</i>	0,68	0,0783	111,6541	0,39528
9	M2Us_2	<i>ISM_SP500_2</i>	0,72	0,0854	112,5846	0,38994
10	Złoto_SP100_2	<i>SP100_1</i>	0,73	0,1047	113,9657	0,3862
11	Bund_Bobl_2	<i>Usdpln_SP500_2</i>	0,68	0,0996	114,5007	0,3852
12	Brent_SP500_1	<i>SP100_1</i>	0,72	0,0395	111,967	0,3712
13	Miedź_2	<i>Miedź_2</i>	0,73	0,0568	113,8836	0,35721
14	Zloto_Brent_1	<i>Brent_SP500_1</i>	0,72	0,0738	115,5488	0,35501
15	M2_Eur_1	<i>Brent_SP500_1</i>	0,72	0,0470	114,57	0,33982
16	USDpln_Brent_3	<i>Brent_SP500_1</i>	0,73	0,0562	115,94	0,33841
17	d_ISM_3	<i>Brent_SP500_1</i>	0,74	0,0713	117,62	0,3367
18	OblUs30_Zloto_2	<i>Brent_SP500_1</i>	0,73	0,0584	117,54	0,33

Źródło: Opracowanie własne.

Tabela 33. Poszczególne modele probitowe, z których usunięto najmniej istotną zmienną dla spreadu Złoto - Dolar / Jen.

Model	Najmniej istotna zmienna	Liczba przypadków poprawnej predykcji	Test ilorazu wiarygodności [wartość p]	Kryt. inform. Akaike'a	Średni błąd absolutny
2a	SP400_2	0,63	0,0356	107,37	0,4472
3a	SP400_2	0,63	0,0318	106,89	0,4388
4a	Usdpln_SP500_2	0,67	0,0870	109,66	0,4269
5a	SP100_1	0,68	0,1476	111,63	0,4268
6a	ISM_SP500_2	0,68	0,2258	113,62	0,4268
7a	ISM_SP500_2	0,69	0,1082	111,37	0,4150
8a	ISM_SP500_2	0,69	0,0505	109,75	0,3956
9a	ISM_SP500_2	0,72	0,0571	110,68	0,3901
10a	SP100_1	0,72	0,0722	112,04	0,3864
11a	Usdpln_SP500_2	0,69	0,0705	112,61	0,3815
12a	SP100_1	0,74	0,0270	110,12	0,3769
13a	Miedź_2	0,73	0,0568	113,88	0,35721
14a	Brent_SP500_1	0,72	0,0527	113,62	0,3552
15a	Brent_SP500_1	0,73	0,0326	112,59	0,3398
16a	Brent_SP500_1	0,73	0,0404	114,01	0,3383
17a	Brent_SP500_1	0,74	0,0525	115,68	0,3366
18a	Brent_SP500_1	0,73	0,0422	115,55	0,3279

Źródło: Opracowanie własne.

Tabela 34. Modeli probitowe na podstawie metody regresji krokowej wstecznej dla spreadu

Złoto – S&P500

Model	Liczba przypadków poprawnej predykcji	Test ilorazu wiarygodności [wartość p]	Kryt. inform. Akaike'a	Średni błąd absolutny
1.2	0,75	0,0307	113,6824	0,32844
1.3	0,73	0,0211	111,7105	0,32852
1.4	0,74	0,0149	109,9454	0,33017
1.5	0,74	0,0105	108,2709	0,33181
1.6	0,73	0,0074	106,6548	0,3332
1.7	0,75	0,0052	105,1735	0,33571
1.8	0,72	0,0037	103,7635	0,33767
1.9	0,74	0,003	102,804	0,34151
1.10	0,70	0,0033	102,7799	0,35236
1.11	0,72	0,0035	102,5779	0,35994
1.12	0,74	0,0037	102,5237	0,36801
1.13	0,72	0,0021	101,0333	0,37174

Źródło: Opracowanie własne.

Następnie stworzono rankingi modeli według wyżej omówionych kryteriów dobroci modelu. W ten sposób powstały rankingi według następujących kryteriów:

- Ranking 1 - Liczba przypadków poprawnej predykcji
- Ranking 2 - Test ilorazu wiarygodności
- Ranking 3 - Kryt. inform. Akaike'a
- Ranking 4 - Średni błąd absolutny

Podobnie jak dla spreadu Złoto – S&P500 powstały rankingi dla poszczególnych kryteriów. Obliczenia przedstawia tabela 35. W analogiczny sposób jak dla modeli dla spreadu Złoto – S&P500 powstał ranking łączny modeli, tabela 36.

Tabela 35. Modele probitowe wg. poszczególnych kryteria dobroci modelu dla spreadu

Złoto – Dolar / Jen

Model	Liczba przypadków poprawnej predykcji	Model	Test ilorazu wiarygodności [wartość p]	Model	Kryt. inform. Akaike'a	Model	Średni błąd absolutny
1.7	75,30%	1.13	0,0021	1.13	101,03	18a	0,3279
1.2	75,30%	1.9	0,003	1.12	102,52	18	0,32796
1.9	74,10%	1.10	0,0033	1.11	102,58	1.2	0,32844
1.12	74,10%	1.11	0,0035	1.10	102,78	1.3	0,32852
1.5	74,10%	1.12	0,0037	1.9	102,80	1.4	0,33017
1.4	74,10%	1.8	0,0037	1.8	103,76	1.5	0,33181
12a	74,10%	1.7	0,0052	1.7	105,17	1.6	0,3332
17a	74,10%	1.6	0,0074	1.6	106,65	1.7	0,33571
17	74,10%	1.5	0,0105	3a	106,89	17a	0,33663
1.6	72,80%	1.4	0,0149	1	107,37	17	0,3367
1.3	72,80%	1.3	0,0211	2a	107,37	1.8	0,33767
15a	72,80%	12a	0,027	3	107,71	16a	0,33833
16a	72,80%	1.2	0,0307	2	107,95	16	0,33841
18a	72,80%	3a	0,0318	1.5	108,27	15a	0,33977
16	72,80%	15a	0,0326	4	109,66	15	0,33982
13a	72,80%	2a	0,0356	4a	109,66	1.9	0,34151
13	72,80%	1	0,0356	8a	109,75	1.10	0,35236
18	72,80%	12	0,0395	1.4	109,95	14	0,35501
10	72,80%	16a	0,0404	12a	110,12	14a	0,35515
1.13	71,60%	18a	0,0422	9a	110,68	13a	0,35721
1.11	71,60%	3	0,0444	7a	111,37	13	0,35721
1.8	71,60%	15	0,047	5	111,63	1.11	0,35994
12	71,60%	8a	0,0505	5a	111,63	1.12	0,36801

c.d. Tabela 35.

15	71,60%	17a	0,0525	8	111,65	12	0,3712
14a	71,60%	14a	0,0527	1.3	111,71	1.13	0,37174
9a	71,60%	2	0,054	12	111,97	12a	0,376941667
10a	71,60%	16	0,0562	10a	112,04	11a	0,381526667
14	71,60%	13a	0,0568	9	112,58	11	0,3852
9	71,60%	13	0,0568	15a	112,59	10	0,3862
1.10	70,40%	9a	0,0571	11a	112,61	10a	0,38639
7	70,40%	18	0,0584	7	113,37	9	0,38994
8a	69,10%	11a	0,0705	14a	113,62	9a	0,39014
11a	69,10%	17	0,0713	6	113,62	8	0,39528
7a	69,10%	10a	0,0722	6a	113,62	8a	0,39556
8	67,90%	14	0,0738	1.2	113,68	7	0,41494
11	67,90%	8	0,0783	13	113,88	7a	0,41498
5a	67,90%	9	0,0854	13a	113,88	6a	0,42676
5	67,90%	4a	0,087	10	113,97	6	0,42676
6a	67,90%	4	0,087	16a	114,01	5a	0,42681
6	67,90%	11	0,0996	11	114,50	5	0,42681
4a	66,70%	10	0,1047	15	114,57	4a	0,42693
4	66,70%	7a	0,1082	14	115,55	4	0,42693
3	65,40%	5a	0,1476	18a	115,55	3	0,42709
2	65,40%	5	0,1476	17a	115,68	3a	0,43882
3a	63,00%	7	0,1659	16	115,94	2	0,43882
2a	63,00%	6a	0,2258	18	117,54	2a	0,44718
1	63,00%	6	0,2258	17	117,62	1	0,44718

Źródło: Opracowanie własne.

Tabela 36. Ranking łączny modeli probitowych dla spreadu Złoto – S&P500

Model	Liczba przypadków poprawnej predykcji	Test ilorazu wiarygodności [wartość p]	Kryt. inform. Akaike'a	Średni błąd absolutny	Punkty
1.7	47	41	41	40	169
1.9	42	46	43	32	163
1.12	43	43	46	25	157
1.5	41	39	34	42	156
1.6	34	40	40	41	155
1.4	40	38	30	43	151
1.8	23	42	42	37	144
1.13	25	47	47	23	142
1.11	24	44	45	26	139
1.2	46	35	13	45	139
1.10	18	45	44	31	138
1.3	33	37	23	44	137
12a	44	36	29	22	131
15a	36	33	19	34	122
18a	38	28	5	47	118
17a	45	24	4	39	112
16a	37	29	9	36	111
18	32	17	2	46	97
12	20	30	22	24	96
14a	28	23	16	29	96
13a	35	20	12	28	95
17	39	15	1	38	93
16	31	21	3	35	90
15	22	26	7	33	88

c.d. Tabela 36.

9a	26	18	28	16	88
13	30	19	11	27	87
8a	15	25	31	14	85
10a	27	14	21	18	80
3a	3	34	39	4	80
2a	2	32	38	2	74
3	5	27	36	5	73
11a	16	16	18	21	71
1	1	31	37	1	70
14	21	13	6	30	70
9	19	11	20	17	67
10	29	7	10	19	65
2	4	22	35	3	64
8	10	12	24	15	61
7a	14	6	27	12	59
4a	7	10	33	7	57
4	6	9	32	6	53
5a	12	5	26	9	52
7	17	3	17	13	50
11	11	8	8	20	47
5	8	4	25	8	45
6a	13	2	15	11	41
6	9	1	14	10	34

Źródło: Opracowanie własne.

Po analizie dopasowań wszystkich modeli wybrano 3 modele.

- Model 1 - model 1.7 był preferowany zarówno pod względem liczba przypadków poprawnej predykcji, jak i rankingu łącznego,
- Model 2 - model 1.13 był preferowany zarówno pod względem testu ilorazu wiarygodności, jak i Kryterium informacyjnym Akaike'a ,

- Model 3 - model 18a był preferowany pod względem średniego błędu absolutnego.
Dodatkowo skonstruowano model 4, dla którego wagi dostarczyła średnia z wag modelu 1, modelu 2 i modelu 3.

Model 1

Estymacja Probit, wykorzystane obserwacje 3/1995 – 12/2001

Zmienna zależna: Złoto – Dolar / Jen

	współczynnik	błąd standardowy	t-Studenta	wartość p	
const	0,145934	0,294111	0,4962	0,6198	
Miedz_3	5,64455	3,04728	1,852	0,064	*
SP400_2	-9,65457	6,83951	-1,412	0,1581	
SP500_1	-6,39704	3,90606	-1,638	0,1015	
Usdpln_SP500_2	-6,76114	6,65127	-1,017	0,3094	
ISM_SP500_2	-4,90331	4,606	-1,065	0,2871	
Ryz_2	-4,48266	2,05527	-2,181	0,0292	**
Zoto_SP100_2	3,98817	3,40285	1,172	0,2412	
Zloto_Brent_1	-3,31849	1,98504	-1,672	0,0946	*
M2_Eur_1	-78,935	47,0511	-1,678	0,0934	*
USDpln_Brent_3	-1,39895	1,82185	-0,7679	0,4426	
ObIUs30_Zloto_2	7,0271	4,37617	1,606	0,1083	

Logarytm wiarygodności -40,58673 Kryt. inform. Akaike'a 105,1735

Liczba przypadków 'poprawnej predykcji' = 61 (75,3%)

Test ilorazu wiarygodności: Chi-kwadrat(11) = 26,6178 [0,0052]

Model 2

Estymacja Probit, wykorzystane obserwacje 3/1995 – 12/2001

Zmienna zależna: Złoto – Dolar / Jen

	współczynnik	błąd standardowy	t-Studenta	wartość p	
const	0,106398	0,271669	0,3916	0,6953	
Miedz_3	6,13179	2,77014	2,214	0,0269	**
SP500_1	-6,21947	3,43517	-1,811	0,0702	*
Ryz_2	-3,43083	1,87525	-1,83	0,0673	*
Zloto_Brent_1	-2,76328	1,73134	-1,596	0,1105	
M2_Eur_1	-82,302	48,7301	-1,689	0,0912	*

Logarytm wiarygodności -44,51663 Kryt. inform. Akaike'a 101,0333

Liczba przypadków 'poprawnej predykcji' = 58 (71,6%)

Test ilorazu wiarygodności: Chi-kwadrat(5) = 18,758 [0,0021]

Model 3

Estymacja Probit, wykorzystane obserwacje 3/1995 – 12/2001

Zmienna zależna: Złoto – Dolar / Jen

	współczynnik	błąd standardowy	t-Studenta	wartość p	
const	0,2884	0,432221	0,6673	0,5046	
Miedz_3	4,98715	3,2546	1,532	0,1254	
SP400_2	-8,38687	7,04065	-1,191	0,2336	
SP500_1	-11,6304	8,53151	-1,363	0,1728	
Usdpln_SP500_2	-5,60957	6,86541	-0,8171	0,4139	
SP100_1	-4,52599	7,17604	-0,6307	0,5282	
ISM_SP500_2	-5,93604	4,8806	-1,216	0,2239	
Soja_3	1,20138	3,32703	0,3611	0,718	
Ryz_2	-3,92595	2,16244	-1,816	0,0694	*
M2Us_2	-40,0544	68,5898	-0,584	0,5592	

c.d. Model 3

Złoto_SP100_2	3,95057	4,30785	0,9171	0,3591
Bund_Bobl_2	-4,95766	22,3354	-0,222	0,8243
Mied_2	-1,67901	2,85565	-0,588	0,5566
Złoto_Brent_1	-3,33281	2,14045	-1,557	0,1195
M2_Eur_1	-70,1134	49,0842	-1,428	0,1532
USDpln_Brent_3	-1,63642	1,89578	-0,8632	0,388
d_ISM_3	-2,24939	4,49704	-0,5002	0,6169
OblUs30_Złoto_2	7,37123	5,51242	1,337	0,1812

Logarytm wiarygodności -39,77586 Kryt. inform. Akaike'a 115,5517

Liczba przypadków 'poprawnej predykcji' = 59 (72,8%)

Test ilorazu wiarygodności: Chi-kwadrat(17) = 28,2395 [0,0422]

5.4.3. Estymacja modeli dla spreadu S&P500 – Dolar / Jen

Model probitowy dla spreadu SP 500 – Dolar / Jen ma postać następującą:

$$P(Y_{t+1} = 1|x) = P(y=1|X_t)$$

gdzie,

X_t – zmienne objaśniające

$Y_{t+1} = 1$, jeśli różnica w ujęciu procentowym między SP 500 a Dolar / Jen będzie dodatnia w okresie jednego miesiąca naprzód względem zmiennych objaśniających, w przeciwnym wypadku $Y_{t+1} = 0$.

Ostatecznie dla spreadu Złoto – Dolar / Jen stworzono 36 modeli. Tabela 37, 38 i 39 przedstawia modele wraz z wartościami kryterii, które były brane pod uwagę przy selekcji modeli. Sposób identyfikacji modeli w tabelach 37 i 38 należy czytać analogicznie jak w rozdziale 3.4. w tabelach 8 i 9. Natomiast modele w tabeli 39 przedstawiają estymacje modeli probitowych na podstawie metody regresji krokowej wstecznej. Numer po kropce w kolejnych modelach oznacza liczbę kolejnych estymacji metodą regresji krokowej wstecznej, czyli im

mniejszy numer po kropce tym więcej usunięto zmiennych najmniej istotnych. Po każdej takiej estymacji najmniej istotna zmienna została usunięta.

Tabela 37. Poszczególne modele probitowe i ich charakterystyki dla spreadu S&P500
– Dolar / Jen.

Model	Zmienne	Najmniej istotna zmienna	Liczba przypadków poprawnej predykcji	Test ilorazu wiarygodności [wartość p]	Kryt. inform. Akaike'a	Średni błąd absolutny
1	SP400_2		54,9%	0,0158	111,6511	0,4659
2	PPrzUS_1	PPrzUS_1	61,0%	0,0139	110,9362	0,4504
3	PrPrzUs_Inf_1	PrPrzUs_Inf_1	58,5%	0,0350	112,8771	0,4502
4	SP500_SP400_1	PrPrzUs_Inf_1	57,3%	0,0376	113,3085	0,4427
5	Usdpln_SP500_2	PrPrzUs_Inf_1	64,6%	0,0229	112,4334	0,4271
6	SP500_2	PrPrzUs_Inf_1	64,6%	0,0391	114,2204	0,4261
7	Zbydło	PrPrzUs_Inf_1	68,3%	0,0076	110,3022	0,3951
8	Brent_3	PrPrzUs_Inf_1	66,7%	0,0102	110,1292	0,3901
9	Zloto_Brent_3	Brent_3	67,9%	0,0169	112,0040	0,3895
10	USDpln_Brent_3	PrPrzUs_Inf_1	70,4%	0,0262	113,8425	0,3880
11	SP100_2	Brent_3	71,6%	0,0323	115,0703	0,3860
12	ISM_SP500_2	SP500_2	71,6%	0,0471	116,9473	0,3836
13	d_ISM_1	SP500_2	80,2%	0,0117	112,9916	0,3533
14	PPrzUS_3	SP500_2	76,5%	0,0138	114,0890	0,3478

Źródło: Opracowanie własne.

Tabela 38. Poszczególne modele probitowe z których usunięto najmniej istotną zmienną dla spreadu S&P500 - Dolar / Jen.

Model	Najmniej istotna zmienna	Liczba przypadków poprawnej predykcji	Test ilorazu wiarygodności [wartość p]	Kryt. inform. Akaike'a	Średni błąd absolutny
2a	PPrzUS_1	61,0%	0,0139	110,9362	0,4504
3a	PrPrzUs_Inf_1	58,5%	0,0350	112,8771	0,4502
4a	PrPrzUs_Inf_1	58,5%	0,0176	111,3655	0,4430
5a	PrPrzUs_Inf_1	64,6%	0,0111	110,4364	0,4271
6a	PrPrzUs_Inf_1	64,6%	0,0211	112,2212	0,4262
7a	PrPrzUs_Inf_1	68,3%	0,0039	108,3118	0,3951
8a	PrPrzUs_Inf_1	66,7%	0,0055	108,1352	0,3901
9a	Brent_3	69,1%	0,0097	110,0074	0,3820
10a	Brent_3	70,4%	0,0160	111,8461	0,3752
11a	PrPrzUs_Inf_1	71,6%	0,0204	113,0743	0,3650
12a	Brent_3	71,6%	0,0311	114,9505	0,3836
13a	SP500_2	80,2%	0,0073	110,9916	0,3533
14a	SP500_2	76,5%	0,0088	112,0929	0,3478

Źródło: Opracowanie własne.

Następnie stworzono rankingi modeli według wyżej omówionych kryteriów dobroci modelu.

W ten sposób powstały rankingi według następujących kryteriów:

- Ranking 1 - Liczba przypadków poprawnej predykcji
- Ranking 2 - Test ilorazu wiarygodności
- Ranking 3 - Kryt. inform. Akaike'a
- Ranking 4 - Średni błąd absolutny

Podobnie jak dla spreadu Złoto – S&P500 powstały rankingi dla poszczególnych kryteriów, tabela 40.

Tabela 39. Modeli probitowe na podstawie metody regresji krokowej wstecznej dla spreadu S&P500 - Dolar / Jen.

Model	Liczba przypadków poprawnej predykcji	Test ilorazu wiarygodności [wartość p]	Kryt. inform. Akaike'a	Średni błąd absolutny
1.1	0,75	0,0507	117,2002	0,38363
1.2	0,74	0,0342	115,2602	0,38395
1.3	0,73	0,0227	113,4005	0,38475
1.4	0,73	0,0149	111,6502	0,3865
1.5	0,72	0,0102	110,1351	0,38856
1.6	0,72	0,0057	108,2481	0,3895
1.7	0,73	0,0057	109,2688	0,39832
1.8	0,74	0,0053	108,8737	0,40648
1.9	0,71	0,0074	109,5078	0,42154

Źródło: Opracowanie własne.

W analogiczny sposób jak dla modeli dla spreadu Złoto – S&P500 powstał ranking łączny modeli. Obliczenia przedstawia tabela 41.

Tabela 40. Modele probitowe wg. poszczególnych kryteria dobroci modelu dla spreadu Złoto –
Dolar / Jen

Model	Liczba przypadków poprawnej predykcji	Model	Test ilorazu wiarygodności [wartość p]	Model	Kryt. inform. Akaike'a	Model	Średni błąd absolutny
13	80,20%	7a	0,0039	7a	108,14	14	0,34780
13a	80,20%	1.8	0,0053	1.6	108,25	14a	0,34780
14	76,50%	8a	0,0055	8a	108,31	13	0,35333
14a	76,50%	1.6	0,0057	1.8	108,87	13a	0,35333
1.1	75,30%	1.7	0,0057	1.7	109,27	11a	0,36501
1.8	74,40%	13a	0,01	1.9	109,51	10a	0,37523
1.2	74,10%	1.9	0,0074	9a	110,01	9a	0,38201
1.7	73,20%	7	0,0076	8	110,1292	12a	0,38362
1.3	72,80%	14a	0,0088	1.5	110,14	1.1	0,38363
1.4	72,80%	9a	0,0097	7	110,3022	12	0,38364
11	71,60%	8	0,0102	5a	110,4364	1.2	0,38395
12	71,60%	1.5	0,0102	2	110,9362	1.3	0,38475
1.5	71,60%	5a	0,0111	2a	110,9362	11	0,38600
1.6	71,60%	13	0,0117	13a	110,99	1.4	0,38650
11a	71,60%	14	0,0138	4a	111,3655	10	0,38801
12a	71,60%	2	0,0139	1.4	111,65	1.5	0,38856
1.9	70,70%	2a	0,0139	1	111,6511	9	0,38948
10	70,40%	1.4	0,0149	10a	111,8461	1.6	0,38950
10a	70,40%	1	0,0158	9	112,004	8	0,39012
9a	69,10%	10a	0,016	14a	112,09	8a	0,39013
7	68,30%	9	0,0169	6a	112,2212	7	0,39506
7a	68,30%	4a	0,0176	5	112,4334	7a	0,39506
9	67,90%	11a	0,0204	3	112,8771	1.7	0,39832

c.d. Tabela 40.

8	66,70%	6a	0,0211	3a	112,8771	1.8	0,40648
8a	66,70%	1.3	0,0227	13	112,9916	1.9	0,42154
5	64,60%	5	0,0229	11a	113,07	6	0,42612
6	64,60%	10	0,0262	4	113,3085	6a	0,42615
5a	64,60%	12a	0,0311	1.3	113,40	5a	0,42710
6a	64,60%	11	0,0323	10	113,8425	5	0,42713
2	61,00%	1.2	0,0342	14	114,089	4	0,44273
2a	61,00%	3	0,0350	6	114,2204	4a	0,44304
3	58,50%	3a	0,0350	12a	114,95	3	0,45017
3a	58,50%	4	0,0376	11	115,0703	3a	0,45017
4a	58,50%	6	0,0391	1.2	115,26	2	0,45044
4	57,30%	12	0,0471	12	116,9473	2a	0,45044
1	54,90%	1.1	0,0507	1.1	117,20	1	0,46589

Źródło: Opracowanie własne.

Tabela 41. Ranking łączny modeli probitowych dla spreadu Złoto – S&P500

Model	Liczba przypadków poprawnej predykcji	Test ilorazu wiarygodności [wartość p]	Kryt. inform. Akaike'a	Średni błąd absolutny	Punkty
13a	35	31	23	33	122
14a	33	28	17	35	113
1.8	31	35	33	13	112
1.6	23	33	35	19	110
1.7	29	32	32	14	107
13	36	23	12	34	105
9a	17	27	30	30	104
7a	15	36	34	15	100
14	34	22	7	36	99

c.d. Tabela 41.

8a	12	34	36	17	99
1.5	24	25	28	21	98
1.9	20	30	31	12	93
1.4	27	19	21	23	90
7	16	29	27	16	88
8	13	26	29	18	86
10a	18	17	19	31	85
11a	22	14	11	32	79
1.3	28	12	9	25	74
9	14	16	18	20	68
5a	9	24	26	9	68
1.2	30	7	3	26	66
12a	21	9	5	29	64
11	26	8	4	24	62
1.1	32	1	1	28	62
10	19	10	8	22	59
2	7	21	25	3	56
12	25	2	2	27	56
2a	6	20	24	2	52
6a	8	13	16	10	47
4a	3	15	22	6	46
5	11	11	15	8	45
1	1	18	20	1	40
3	5	6	14	5	30
6	10	3	6	11	30
3a	4	5	13	4	26
4	2	4	10	7	23

Źródło: Opracowanie własne.

Po analizie dopasowań wszystkich modeli wybrano trzy modele.

- Model 1 - model 13a był preferowany zarówno pod względem liczba przypadków poprawnej predykcji, jak i rankingu łącznego,
 - Model 2 - model 7a był preferowany zarówno pod względem testu ilorazu wiarygodności, jak i Kryterium informacyjnym Akaike'a ,
 - Model 3 - model 14 był preferowany pod względem średniego błędu absolutnego.
- Dodatkowo skonstruowano model 4, dla którego wagi dostarczyły średnie wagi z modelu 1, modelu 2 i modelu 3.

Model 1

Estymacja Probit, wykorzystane obserwacje 3/1995 – 12/2001

Zmienna zależna: S&P500 – Dolar / Jen

	błąd				
	współczynnik	standardowy	t-Studenta	wartość p	
const	0,0590168	0,258025	0,2287	0,8191	
SP400_2	-19,8258	7,06215	-2,807	0,005	***
PPrzUS_1	75,6292	95,8899	0,7887	0,4303	
PrPrzUs_Inf_1	-0,0988909	0,893391	-0,1107	0,9119	
SP500_SP400_1	-10,6389	6,44292	-1,651	0,0987	*
Usdpln_SP500_2	-13,8815	8,58456	-1,617	0,1059	
Zbydo_1	-8,81782	3,80712	-2,316	0,0206	**
Brent_3	-8,42685	9,97811	-0,8445	0,3984	
Zloto_Brent_3	-3,57438	5,09951	-0,7009	0,4833	
USDpln_Brent_3	-7,16934	7,5781	-0,9461	0,3441	
SP100_2	1,80203	8,60879	0,2093	0,8342	
ISM_SP500_2	1,73349	5,0614	0,3425	0,732	
d_ISM_1	12,1684	4,98713	2,44	0,0147	**

c.d. Model 1.

Logarytm wiarygodności -42,49582 Kryt. inform. Akaike'a 110,9916

Liczba przypadków 'poprawnej predykcji' = 66 (80,2%)

Test ilorazu wiarygodności: Chi-kwadrat(6) = 19,1692 [0,0073]

Model 2

Estymacja Probit, wykorzystane obserwacje 3/1995 – 12/2001

Zmienna zależna: S&P500 – Dolar / Jen

		błąd			
	współczynnik	standardowy	t-Studenta	wartość p	
const	0,0236945	0,17225	0,1376	0,8906	
SP400_2	-17,7512	6,40559	-2,771	0,0056	***
PPrzUS_1	62,1941	29,8102	2,086	0,0369	**
SP500_SP400_1	-9,1912	5,77777	-1,591	0,1117	
Usdpln_SP500_2	-7,79226	6,78339	-1,149	0,2507	
SP500_2	3,95808	8,2118	0,482	0,6298	
Zbydo_1	-8,7724	3,7067	-2,367	0,018	**

Logarytm wiarygodności -47,15589 Kryt. inform. Akaike'a 108,3118

Liczba przypadków 'poprawnej predykcji' = 56 (68,3%)

Test ilorazu wiarygodności: Chi-kwadrat(6) = 19,1692 [0,0039]

Model 3

Estymacja Probit, wykorzystane obserwacje 3/1995 – 12/2001

Zmienna zależna: S&P500 – Dolar / Jen

	współczynnik	błąd standardowy	t-Studenta	wartość p	
const	-0,0420095	0,28202	-0,149	0,8816	
SP400_2	-18,9896	8,36455	-2,27	0,0232	**
PPrzUS_1	73,3286	95,7083	0,7662	0,4436	
PrPrzUs_Inf_1	-0,206846	0,899881	-0,2299	0,8182	
SP500_SP400_1	-11,122	6,70205	-1,659	0,097	*
Usdpln_SP500_2	-13,1129	8,93344	-1,468	0,1421	
SP500_2	-2,00391	32,4229	-0,06181	0,9507	
Zbydo_1	-9,70354	3,96873	-2,445	0,0145	**
Brent_3	-6,8672	10,0509	-0,6832	0,4945	
Zloto_Brent_3	-2,60248	5,2206	-0,4985	0,6181	
USDpln_Brent_3	-6,23315	7,70223	-0,8093	0,4184	
SP100_2	3,00609	28,2595	0,1064	0,9153	
ISM_SP500_2	1,72084	5,15077	0,3341	0,7383	
d_ISM_1	11,7295	5,20939	2,252	0,0243	**
PPrzUS_3	31,9315	33,795	0,9449	0,3447	

Logarytm wiarygodności -42,04452 Kryt. inform. Akaike'a 114,0890

Liczba przypadków 'poprawnej predykcji' = 62 (76,5%)

Test ilorazu wiarygodności: Chi-kwadrat(14) = 28,0897 [0,0138]

5.4.4. Metodologia budowy strategii inwestycyjnej.

W ramach budowy globalnego portfela, autor zbudował oddzielne modele dla spreadów:

- Złoto – S&P 500,
- Złoto – Dolar/Jen,
- S&P 500 – Dolar/Jen.

Dla każdego ze spreadów przeprowadzono badanie zachowania się portfela złożonego z każdego dwóch instrumentów.

5.4.4.1. Metodologia i wyniki badań strategii dla poszczególnych spreadów.

Po wyselekcjonowaniu modeli, przystąpiono do budowy prognoz. Badanie polegało na dynamicznym ujęciu prognozowania na podstawie modeli probitowych. Autor dysponując danym zbiorem uczącym z okresu 3/1995 do 12/2001 przeprowadzał prognozy na 12 miesięcy naprzód. Po dokonaniu prognozy, kolejnym krokiem było dodanie wygasłych prognoz do zbioru uczącego się. Po każdym takim etapie do zbioru uczącego przypisywano wygasłe prognozy z ostatnich 12 miesięcy i jednocześnie nie odcinano obserwacji najstarszych. Tym samym zbiór uczący powiększał się z każdym etapem poprzez dodawanie najnowszych obserwacji do zbioru uczącego się. W ramach tego podejścia zastosowano 3 strategie konstrukcji portfela dla każdego ze spreadów. Dla spreadu Złoto – S&P500 strategie były następujące:

- 3) Strategia 1. Otrzymana prognoza zwracała wagę jaką w danym miesiącu przypisano w portfelu dla Złota i S&P500. Suma wag = 100. Z tym że zajmowano krótką pozycję na instrumencie, który otrzymał prognozę mniejszą lub równą 0,5 oraz długą pozycję na instrumencie, który otrzymał prognozę większą niż 0,5.
- 4) Strategia 2. Otrzymana prognoza zwracała wagę jaką w danym miesiącu przypisano w portfelu dla Złota i S&P500. Suma wag = 100.
- 5) Strategia 3. Otrzymana prognoza zwracała decyzję czy cały kapitał będzie lokowany w Złoto, czy S&P500. Jeśli otrzymana wartość była większa lub równa od 0,5 wówczas cały kapitał lokowano w Złoto, w przeciwnym wypadku cały kapitał było lokowany w S&P500.

Analogicznie zostały zbudowane strategie dla dwóch pozostałych spreadów.

Jako benchmark dla strategii 2 autor zaproponował strategię polegającą na kupieniu Złota, indeks S&P 500 oraz kupieniu dolara za jeny w równych proporcjach (równe wagi).

Jako globalny benchmark autor zaproponował strategię polegającą na zajęciu pozycji długiej w indeks S&P500 i utrzymywanie tej pozycji do końca okresu inwestycyjnego.

Tabele 42, 43 i 44 zawierają wyniki zastosowania strategii 1, 2 oraz 3 dla spreadu Złoto – S&P500 w porównaniu ze benchmarkiem.

Tabela 42. Wyniki portfela opartego na strategii 1 dla spreadu Złoto – S&P500 oraz benchmark.

	Model 1	Model 2	Model 3	Model ważony	Kup i trzymaj SP500	Kup i trzymaj Złoto i S&P500
Stopa zwrotu / odchylenie standardowe	8,27	11,72	5,99	6,50	-5,08	14,59
Skumulowana stopa zwrotu	34,63% ²⁴	46,72%	25,64%	26,82%	-22,24%	51,72%
Średnia miesięczna stopa zwrotu	0,39%	0,52%	0,29%	0,30%	-0,25%	0,58%
Odchylenie standardowe	4,19%	3,99%	4,28%	4,13%	4,38%	3,55%

Opracowanie: Źródło własne.

Następnie autor przeprowadził analizę łączną zaprezentowanych modeli i w tabeli 45 przedstawił ich porównanie. Wartości w tabeli przedstawiają średnią dla danego modelu z 3 strategii.

Tabele 46, 47 i 48 zawierają wyniki zastosowania strategii 1, 2 oraz 3 dla spreadu Złoto – Dolar / Jen w porównaniu z benchmarkiem.

Tabela 43. Wyniki portfela opartego na strategii 2 dla spreadu Złoto – S&P500.

	Model 1	Model 2	Model 3	Model ważony
Stopa zwrotu / odchylenie standardowe	13,29	16,84	11,66	13,94
Skumulowana stopa zwrotu	59,26%	69,59%	52,76%	60,53%
Średnia miesięczna stopa zwrotu	0,67%	0,78%	0,59%	0,68%
Odchylenie standardowe	4,46%	4,13%	4,52%	4,34%

Opracowanie: Źródło własne.

²⁴ Podane stopy zwrotu wyniki nie uwzględniają kosztów transakcyjnych.

Tabela 44. Wyniki portfela opartego na strategii 3 dla spreadu Złoto – S&P500.

	Model 1	Model 2	Model 3	Model ważony
Stopa zwrotu / odchylenie standardowe	11,39	16,15	9,06	10,38
Skumulowana stopa zwrotu	58,21%	79,50%	46,22%	52,86%
Średnia miesięczna stopa zwrotu stopa zwrotu	0,65%	0,89%	0,52%	0,59%
Odchylenie standardowe	5,11%	4,92%	5,10%	5,09%

Opracowanie: Źródło własne.

Tabela 45. Średnia dla danego modelu z zaprezentowanych strategii spreadu Złoto – S&P500.

	Model 1	Model 2	Model 3	Model ważony
Stopa zwrotu / odchylenie standardowe	10,98	14,90	8,90	10,27
Skumulowana stopa zwrotu	50,70%	65,27%	41,54%	46,74%
Średnia miesięczna stopa zwrotu stopa zwrotu	0,57%	0,73%	0,47%	0,53%
Odchylenie standardowe	4,59%	4,35%	4,64%	4,52%

Opracowanie: Źródło własne.

Tabela 46. Wyniki portfela opartego na strategii 1 dla spreadu Złoto – Dolar / Jen oraz benchmark.

	Model 1	Model 2	Model 3	Model ważony	Kup i trzymaj SP500	Kup i trzymaj Złoto i Dolar / Jen
Stopa zwrotu / odchylenie standardowe	9,68	3,48	14,06	-4,50	-5,08	20,07
Skumulowana stopa zwrotu	31,48%	10,94%	45,83%	-14,42%	-22,24%	46,66%
Średnia miesięczna stopa zwrotu stopa zwrotu	0,35%	0,12%	0,51%	-0,16%	-0,25%	0,52%
Odchylenie standardowe	3,25%	3,14%	3,26%	3,21%	4,38%	2,33%

Opracowanie: Źródło własne.

Tabela 47. Wyniki portfela opartego na strategii 2 dla spreadu Złoto – Dolar / Jen.

	Model 1	Model 2	Model 3	Model ważony
Stopa zwrotu / odchylenie standardowe	18,80	16,77	18,57	18,44
Skumulowana stopa zwrotu	49,70%	44,62%	50,13%	48,15%
Średnia miesięczna stopa zwrotu stopa zwrotu	0,56%	0,50%	0,56%	0,54%
Odchylenie standardowe	2,64%	2,66%	2,70%	2,61%

Opracowanie: Źródło własne.

Tabela 48. Wyniki portfela opartego na strategii 3 dla spreadu Złoto – Dolar / Jen.

	Model 1	Model 2	Model 3	Model ważony
Stopa zwrotu / odchylenie standardowe	14,65	11,00	18,94	3,29
Skumulowana stopa zwrotu	53,21%	40,52%	69,34%	11,93%
Średnia miesięczna stopa zwrotu stopa zwrotu	0,60%	0,46%	0,78%	0,13%
Odchylenie standardowe	3,63%	3,68%	3,66%	3,63%

Opracowanie: Źródło własne.

Następnie autor analizę łączną zaprezentowanych modeli i w tabeli 49 przedstawił porównanie ich. Wartości w tabeli przedstawiają średnią dla danego modelu z trzech strategii.

Tabele 50, 51 i 52 zawierają wyniki zastosowania strategii 1, 2 oraz 3 dla spreadu S&P500 – Dolar / Jen w porównaniu ze benchmarkiem.

Tabela 49. Średnia dla danego modelu z zaprezentowanych strategii spreadu Złoto – Dolar / Jen.

	Model 1	Model 2	Model 3	Model ważony
Stopa zwrotu / odchylenie standardowe	14,37	10,42	17,19	5,74
Skumulowana stopa zwrotu	44,80%	32,03%	55,10%	15,22%
Średnia miesięczna stopa zwrotu stopa zwrotu	0,50%	0,36%	0,62%	0,17%
Odchylenie standardowe	3,18%	3,16%	3,21%	3,15%

Opracowanie: Źródło własne.

Tabela 50. Wyniki portfela opartego na strategii 1 dla spreadu S&P500 – Dolar / Jen oraz benchmark.

	Model 1	Model 2	Model 3	Model ważony	Kup i trzymaj SP500	Kup i trzymaj S&P500 i Dolar / Jen
Stopa zwrotu / odchylenie standardowe	-4,14	-7,06	-6,19	-6,80	-5,08	-11,74
Skumulowana stopa zwrotu	-10,68%	-17,72%	-15,62%	-17,03%	-22,24%	-27,30%
Średnia miesięczna stopa zwrotu stopa zwrotu	-0,12%	-0,20%	-0,18%	-0,19%	-0,25%	-0,31%
Odchylenie standardowe	2,58%	2,51%	2,52%	2,50%	4,38%	2,33%

Opracowanie: Źródło własne.

Następnie autor przedstawił analizę łączną zaprezentowanych modeli i w tabeli 53 przedstawił ich porównanie. Wartości w tabeli przedstawiają średnią dla danego modelu z trzech strategii.

Tabela 51. Wyniki portfela opartego na strategii 2 dla spreadu S&P500 – Dolar / Jen.

	Model 1	Model 2	Model 3	Model ważony
Stopa zwrotu / odchylenie standardowe	-4,87	-8,77	-6,15	-6,64
Skumulowana stopa zwrotu	-14,36%	-25,76%	-17,61%	-19,24%
Średnia miesięczna stopa zwrotu stopa zwrotu	-0,16%	-0,29%	-0,20%	-0,22%
Odchylenie standardowe	2,95%	2,94%	2,87%	2,90%

Opracowanie: Źródło własne.

Tabela 52. Wyniki portfela opartego na strategii 3 dla spreadu S&P500 – Dolar / Jen.

	Model 1	Model 2	Model 3	Model ważony
Stopa zwrotu / odchylenie standardowe	-4,77	-9,07	-5,24	-6,89
Skumulowana stopa zwrotu	-15,36%	-33,51%	-18,84%	-24,72%
Średnia miesięczna stopa zwrotu stopa zwrotu	-0,17%	-0,38%	-0,21%	-0,28%
Odchylenie standardowe	3,22%	3,69%	3,59%	3,59%

Opracowanie: Źródło własne.

Tabela 53. Średnia dla danego modelu z zaprezentowanych strategii spreadu S&P500 –
Dolar / Jen.

	Model 1	Model 2	Model 3	Model ważony
Stopa zwrotu / odchylenie standardowe	-4,45	-8,07	-5,72	-6,85
Skumulowana stopa zwrotu	-13,02%	-25,62%	-17,23%	-20,87%
Średnia miesięczna stopa zwrotu stopa zwrotu	-0,15%	-0,29%	-0,19%	-0,23%
Odchylenie standardowe	2,90%	3,10%	3,06%	3,04%

Opracowanie: Źródło własne.

5.4.4.2. Metodologia i wyniki badań dla strategii głównej.

Strategia główna polega na dobraniu wag dla poszczególnych instrumentów w taki sposób, że:

$$\text{ProbitPortfolio} = [(w1+w2) + (w3+w4) + (w5+w6)] / 3,$$

gdzie:

ProbitPortfolio – wagi w portfelu dla strategii głównej

w1 – waga dla Złota z modelu równoważonego dla spreadu Złoto – S&P500

w2 - waga dla Złota z modelu równoważonego dla spreadu Złoto – Dolar / Jen

w3 - waga dla indeksu S&P500 z modelu równoważonego dla spreadu Złoto – S&P500

w4 - waga dla indeksu S&P500 z modelu równoważonego dla spreadu S&P500 – Dolar /
Jen

w5 - waga dla Dolar / Jen z modelu równoważonego dla spreadu Złoto – Dolar / Jen

w6 - waga dla Dolar / Jen z modelu równoważonego dla spreadu S&P500 – Dolar / Jen

W ten sposób autor otrzymał wagi dla poszczególnych instrumentów. Alokacja aktywów odbywała się pomiędzy Złoto, indeks S&P500 oraz Dolar / Jen. Suma wag zawsze była równa 100%. Podobnie jak w przypadku strategii cząstkowych wyróżniono 3 rodzaje strategii

- Strategia 1. Zajmowano krótką pozycję na instrumencie, który otrzymał prognozę najmniejszą oraz długą pozycję na instrumencie, który otrzymał prognozę największą.
- Strategia 2. Otrzymana prognoza zwracała wagę jaką w danym miesiącu przypisano w portfelu dla Złota, S&P500 oraz Dolar / Jen. Suma wag = 100.
 - Strategia 3. Cały kapitał lokowano, długą pozycją, w instrument, któremu przypisano największą wagę.

Dodatkowym benchmarkiem dla strategii głównej będzie strategia momentum, w trzech wersjach:

- Strategia momentum 1 polega ona na zajęciu długiej pozycji na instrumencie, który w miesiącu w czasie t-1 zanotował najniższą stopę zwrotu.
- Strategia momentum 2 polega ona na zajęciu długiej pozycji na instrumencie, który w miesiącu w czasie t-1 zanotował najwyższą stopę zwrotu
- Strategia momentum 3 polega ona na zajęciu długiej pozycji na instrumencie, który w miesiącu w czasie t-1 zanotował najwyższą stopę zwrotu oraz na zajęciu pozycji krótkiej na instrumencie który w miesiącu w czasie t-1 zanotował najniższą stopę zwrotu

Strategia pasywna polega na zajęciu długiej pozycji na wszystkich 3 instrumentach w równych proporcjach i utrzymywania takiego składu portfela przez cały horyzont inwestycyjny.

Poniżej w tabeli 54 zaprezentowano wyniki strategii głównej dla strategii 1. Natomiast tabela 55 wyniki dla uśrednionych strategii probitowych oraz strategii momentum.

Dla zobrazowania przebiegu procesu inwestycyjnego przedstawiono wykres 19, który przedstawia skumulowane wartości stóp zwrotu dla strategii z wykorzystaniem modelu probitowego. Natomiast wykres 20 przedstawia zachowanie się strategii momentum podczas całego horyzontu inwestycyjnego.

Następnie autor postanowił porównać, wykres 21, dwie najbardziej skorelowane ze sobą strategię, czyli strategię drugą oraz strategię pasywną. Strategię te, są podobne jeśli chodzi o zasady selekcji instrumentów. W obu wybieramy wszystkie trzy instrumenty do portfela. W strategii pasywnej wagi są stałe, natomiast w strategii drugiej wagi dostarcza model probitowy.

Tabela 54. Wyniki portfela opartego na strategii 1, 2 oraz 3 oraz benchmark

	Strategia 1	Strategia 2	Strategia 3	Strategia pasywna	Momentum 1	Momentum 2	Momentum 3
Stopa zwrotu / odchylenie standardowe	5,41	11,92	8,91	9,53	-6,87	16,41	17,37
Skumulowana stopa zwrotu	30,83%	29,81%	35,56%	23,69%	-29,21%	78,27%	107,48%
Średnia miesięczna stopa zwrotu stopa zwrotu	0,35%	0,33%	0,40%	0,27%	-0,33%	0,89%	1,22%
Odchylenie standardowe	5,70%	2,50%	3,99%	2,49%	4,25%	4,77%	6,19%

Opracowanie: Źródło własne.


Tabela 55. Uśrednione wyniki portfela.

	Strategie probitowe	Strategie momentum
Stopa zwrotu / odchylenie standardowe	8,75	8,97
Skumulowana stopa zwrotu	32,07%	52,18%
Średnia miesięczna stopa zwrotu stopa zwrotu	0,36%	0,59%
Odchylenie standardowe	4,06%	5,07%

Opracowanie: Źródło własne.


Zauważyć można, iż strategia druga w większości okresu przeważa nad strategią pasywną, jednak w momentach gdy obie strategie notują trend spadkowy, wówczas strategia pasywna traci relatywnie mniej niż strategia druga. Dla zobrazowania różnicy, w czasie trwania procesu inwestycyjnego, jaka występuje między obiema strategiami zaprezentowano wykres 22, który pokazuje spread - różnicę między skumulowanymi stopami zwrotu dla strategii drugiej oraz strategii pasywnej.

Wykres 19. Zestawienie skumulowanych stóp zwrotu dla strategii 1, 2 oraz 3.




Opracowanie: Źródło własne.

Wykres 20. Skumulowane stopy zwrotu dla strategii momentum.



Opracowanie: Źródło własne.


Wykres 21. Skumulowane stopy zwrotu dla strategii 2 oraz strategii pasywnej.



Opracowanie: Źródło własne.

Następnym krokiem była przedstawienie skuteczności strategii 1 i 2 opartych o teorię zasadę momentum. Autor porównał je do strategii 3, która w najbliższy sposób oddaje podobieństwo w zasadach selekcji instrumentów, wykres 23. W obu strategiach momentum wybierany jest zawsze jeden instrument do portfela według z góry określonej zasady, natomiast w strategii 3 również wybierany jest tylko jeden instrument według wskazań modelu probitowego.


Wykres 22. Różnica w skumulowanych stopach zwrotu dla strategii 2 oraz strategii pasywnej.



Opracowanie: Źródło własne.


Ostatnim porównaniem było zestawienie strategii momentum 3 oraz strategii 1, wykres 24. W obu przypadkach do portfela wybierane są dwa instrumenty, jeden jest kupowany, natomiast drugi sprzedawany.

Wykres 23. Skumulowane stopy zwrotu dla strategii momentum 1 oraz 2 oraz strategii 3.



Opracowanie: Źródło własne.

Wykres 24. Skumulowane stopy zwrotu dla strategii momentum 3 oraz strategii 1.



Opracowanie: Źródło własne.

5.4.4.3. Ujęcie strategii głównej z perspektywy polskiego inwestora

Dotychczas wszelkie wyniki uzyskiwane przez poszczególne strategie w tym rozdziale bazowały na ujęciu z perspektywy inwestora amerykańskiego. W tej części pracy autor przedstawi wyniki strategii głównej z perspektywy polskiego inwestora, którego walutą bazową jest polski złoty.

W celu dokonania takich obliczeń, wyniki z każdego miesiąca dla strategii 1, 2 i 3 należy dodatkowo zmodyfikować o zmianę kursu waluty USDpln. W ten sposób że:

$$\%X_{pln,i,k} = \%X_{usd,i,k} - \%d_USDpln_k,$$

Gdzie:

$\%X_{pln,i,k}$ – wynik z i-tej strategii w miesiącu k, ujęty w polskich złotych

$\%X_{usd,i,k}$ – wynik z i-tej strategii w miesiącu k, ujęty w dolarach amerykańskich

$\%d_USDpln_k$ – zmiana kursu USDpln w miesiącu k, w ujęciu procentowym.

W tabeli 56 umieszczono porównanie wyników dla strategii głównej z perspektywy inwestora amerykańskiego oraz inwestora polskiego, który był narażony na dodatkowe ryzyko kursowe.

Tabela 56. Wyniki startegii głównej z perspektywy inwestora amerykańskiego i polskiego.

	Strategia 1	Strategia 2	Strategia 3	Strategia 1	Strategia 2	Strategia 3
	Inwestor amerykański			Inwestor polski		
Stopa zwrotu / odchylenie standardowe	5,41	11,92	8,91	6,72	8,58	8,67
Skumulowana stopa zwrotu	30,83%	29,81%	35,56%	44,34%	43,33%	49,07%
Odchylenie standardowe	5,70%	2,50%	3,99%	6,59%	5,05%	5,66%

Opracowanie: Źródło własne.

5.5. Wyniki badań nad poszczególnym kryteriami dobroci modelu.

Kolejnym etapem było obliczenie wyników dla kryteriów wyboru modeli. Wnioski idące z tej analizy może zniekształcić fakt, iż kierując się pięcioma kryteriami wybrano tylko 3 modele. Zastosowano, więc połączenie kryteriów, które występowały łącznie dla danego modelu i tak:

- Kryterium 1 – zawiera w sobie modele najbardziej efektywne pod względem:
 - Ilorazu szans
 - Rankingu łącznego
- Kryterium 2 - zawiera w sobie modele najbardziej efektywne pod względem:
 - Kryterium Akaike’a
 - Test ilorazu wiarygodności
- Kryterium 3 - zawiera w sobie modele najbardziej efektywne pod względem:
 - Absolutny błąd prognozy

W celu otrzymania wyników autor uśrednił poszczególne modele ze wszystkich strategii. Otrzymane wyniki przedstawia tabela 57.

Tabela 57. Wyniki według przyjętych kryteriów dobroci modelu.

	Stopa zwrotu / odchylenie standardowe	Skumulowana stopa zwrotu
Kryterium 1	6,921	27,49%
Kryterium 2	5,674	23,89%
Kryterium 3	6,744	26,47%

Zródło: Opracowanie własne.

5.6. Wyniki badań nad istotnością zmiennych opisujących modele spreadów.

Spread Złoto – S&P500. Tabela 58 zawiera wybrane zmienne²⁵, których wartości współczynnika p zostały uśrednione. Natomiast tabela 59 pokazuje miejsce wybranych zmiennych w rankingu Simsa oraz wartość p z tego rankingu.

Tabela 58. Wartości współczynnika p dla poszczególnych modeli oraz wartość średnia.

Zmienna	Model 1	Model 2	Model 3	Średnia wartość p
OblUs30_Zloto_2	0,0074	0,0107	0,0093	0,009 ***
Zloto_Brent_1	0,0248	0,0646	0,0466	0,045 **
SP400_1	0,0253	0,0414	0,0859	0,051 *

Zródło: Opracowanie własne.

Tabela 59. Ranking Simsa dla wybranych zmiennych.

Zmienna	Miejsce	Wartość p
OblUs30_Zloto_2	7	0,0245 ***
SP400_1	10	0,0341 ***
Zloto_Brent_1	13	0,0465 ***

Zródło: Opracowanie własne.

Następnie przeprowadzono symulację jak zachowywał by się portfel inwestycyjny, wykres 25, gdyby inwestować na podstawie zachowania się najbardziej istotnej zmiennej w badanych modelach, która okazała się OblUs30_Zloto_2. Na wykresie zaznaczono okres treningowy: po

²⁵ Autor wybrał tylko zmienne, które we wszystkich trzech modelach dla spreadu Złoto – S&P500 były istotne przy poziomie ufności minimum 0,1


lewej stronie wykresu oraz okres testowy: po prawej stronie wykresu. We wszystkich efektywnych modelach znak przy tej średnio najistotniejszej zmiennej był dodatni, a więc kierowano się zasada; jeśli nastąpi wzrost zmiennej *OblUs30_Zloto_2*, wówczas nastąpi wzrost spreadu Złoto – S&P500. Symulacja została przeprowadzona za cały okres aby pokazać czy dana zależność jest stabilna również po na próbie treningowej. Wyniki, tabela 60, zaprezentowano poniżej.

Tabela 60. Charakterystyki ilościowe dla portfela skonstruowanego na podstawie zmiennej *OblUs30_Zloto_2*

	Zbiór uczący - okres 2/1995 - 12/2001	Zbiór testowy - okres 1/2002 - 5/2008
Skumulowana stopa zwrotu	84,89%	-10,68%
Odchylenie standardowe	5,99%	6,87%

Źródło: Opracowanie własne.

Wykres 25. Skumulowana stopa zwrotu dla strategii uwzględniającej tylko zmienną *OblUs30_Zloto_2*.



Źródło: Opracowanie własne.

Spread Złoto – Dolar / Jen. Tabela 61 zawiera wybrane zmienne²⁶, których wartości współczynnika p zostały uśrednione. Natomiast tabela 62 pokazuje miejsce wybranych zmiennych w rankingu Simsa oraz wartość p z tego rankingu.

Tabela 61. Wartości współczynnika p dla poszczególnych modeli oraz wartość średnia.

Zmienna	Model 1	Model 2	Model 3	Średnia wartość p
Ryz_2	0,0292	0,0673	0,0694	0,055

Źródło: Opracowanie własne.

Tabela 62. Ranking Simsa dla wybranych zmiennych.

Zmienna	Miejsce	Wartość p
Ryz_2	8	0,0263

Źródło: Opracowanie własne.

Współczynnik kierunkowy dla zmiennej Ryz_2 we wszystkich modelach miał ten sam znak. Strategia inwestycyjna z wykorzystaniem zmiennej Ryz_2 polegałaby więc na sprzedaży spreadu w czasie t wówczas gdy zmiana zmiennej Ryz_2 w czasie t-2 jest dodatnia oraz na zakupie spreadu w czasie t wówczas gdy zmiana zmiennej Ryz_2 w czasie t-2 jest ujemna. Poniżej zaprezentowano wyniki, tabela 62a, strategii inwestycyjnej z wykorzystaniem zmiennej Ryz_2 oraz wykres 26 symulujący zachowanie się portfela inwestycyjnego opartego o tę strategię.


Tabela 62a. Charakterystyki ilościowe dla portfela skonstruowanego na podstawie zmiennej Ryz_2

	Zbiór uczący - okres 2/1995 - 12/2001	Zbiór testowy - okres 1/2002 - 5/2008
Skumulowana stopa zwrotu	99,09%	47,24%
Odchylenie standardowe	5,71%	6,38%

Źródło: Opracowanie własne.

²⁶ Autor wybrał tylko zmienne, które we wszystkich trzech modelach dla spreadu Złoto – Dolar / Jen były istotne przy poziomie ufności minimum 0,1

Wykres 26. Skumulowana stopa zwrotu dla strategii uwzględniającej tylko zmienną Ryz_2.



Źródło: Opracowanie własne.

Spread S&P500 – Dolar / Jen. Tabela 63 zawiera wybrane zmienne²⁷, których wartości współczynnika p zostały uśrednione. Natomiast tabela 64 pokazuje miejsce wybranych zmiennych w rankingu Simsa oraz wartość p z tego rankingu.

Tabela 63. Wartości współczynnika p dla poszczególnych modeli oraz wartość średnia.

Zmienna	Model 1	Model 2	Model 3	Średnia wartość p
SP400_2	0,005	0,0056	0,0232	0,011
Zbydo_1	0,018	0,018	0,0145	0,017

Źródło: Opracowanie własne.

²⁷ Autor wybrał tylko zmienne, które we wszystkich trzech modelach dla spreadu Złoto – Dolar / Jen były istotne przy poziomi ufności minimum 0,1

Tabela 64. Ranking Simsa dla wybranych zmiennych.

Zmienna	Miejsce	Wartość p
SP400_2	1	0,0008
Zbydo_1	7	0,0387

Źródło: Opracowanie własne.


Współczynnik kierunkowy dla zmiennej SP400_2 we wszystkich modelach miał ten sam znak. Strategia inwestycyjna z wykorzystaniem zmiennej SP400_2 więc polegałaby na sprzedaży spreadu w czasie t wówczas gdy zmiana zmiennej SP400_2 w czasie t-2 jest dodatnia i na zakupie spreadu w czasie t wówczas gdy zmiana zmiennej SP400_2 w czasie t-2 jest ujemna. Poniżej zaprezentowano wyniki strategii inwestycyjnej, tabela 65, z wykorzystaniem zmiennej SP400_2 oraz wykres 27 symulujący zachowanie się portfela inwestycyjnego opartego o tę strategię.

Tabela 65. Charakterystyki ilościowe dla skonstruowanego na podstawie zmiennej SP400_2.

	Zbiór uczący - okres 2/1995 - 12/2001	Zbiór testowy - okres 1/2002 - 5/2008
Skumulowana stopa zwrotu	116,57%	4,48%
Odchylenie standardowe	6,39%	4,82%

Źródło: Opracowanie własne.

Wykres 27. Skumulowana stopa zwrotu dla strategii uwzględniającej tylko zmienną SP400_2.



Źródło: Opracowanie własne.

5.7. Analiza wyników.

5.7.1. Test Simsa

Zmienną, która najistotniej wpływa na przyszłe zachowanie się spreadu Złoto – S&P500 została PPrzUS_1. W oszacowanych modelach probitowych możemy zauważyć, iż zmienna ta posiada współczynnik kierunkowy ujemny. W praktyce rynków finansowych oznaczać to będzie relatywnie lepsze zachowanie się indeksu S&P500 od Złota w czasie t , gdy miesiąc wcześniej zmiana produkcji przemysłowej w Stanach Zjednoczonych była dodatnia. Jest to merytorycznie uzasadnione. Pozytywne tendencje w gospodarce wpływają bowiem na zmniejszenie awersji do ryzyka i realokację aktywów z mniej ryzykownych, tj. złoto, na te bardziej ryzykowne, tj. rynek akcji.

Najistotniejszym predyktorem dla spreadu Złoto – Dolar / Jen okazała się zmienna Miedź_3. Wysoko w rankingu znalazła się również zmienna Miedź_2. Oznaczać to może dużą siłę predykcyjną miedzi do wyjaśniania zależności dla relacji złota i dolara względem jena.

Wzrost kursu złota powinien w praktyce osłabiać dolara, natomiast jen nie reaguje w specjalny sposób na ruchy na złocie, raczej jest neutralny względem tego surowca. Wzrost ceny miedzi w naturalny sposób powinien powiększać spread między Złoto – Dolar / Jen oraz zmniejszać awersję inwestorów do ryzyka. Co jest w tym przypadku interesujące; zmiany ceny miedzi z dużym, bo w tym przypadku aż 3 miesięcznym wyprzedzeniem prognozują zmianę relacji Złoto – Dolar / Jen. Fakt ten potwierdza obecność wysoko w rankingu Simsa opóźnionej o 2 miesiące zmiennej Miedź_2.

W kolejnej omawianej relacji najistotniejszą zmienną prognozującą spread S&P500 – Dolar / Jen okazała się zmienna SP400_2. W okresach dużych nadziei na ożywienie gospodarcze Inwestorzy pozbywają się bezpiecznej waluty jaka jest dolar, często kupując za niego jena, który jest wykorzystywany do zakupów surowców przez Japończyków, którzy są importerami netto większości surowców. Współczynnik kierunkowy przy zmiennej SP400_2 jest ujemny. Jest to dość niespodziewany fakt. Co warto zauważyć, przy zmiennej SP500_SP400_1 znak jest również ujemny. Taka kombinacja jest w samej swojej istocie skomplikowana. Oznaczać ona mogłaby bowiem, że sytuacja gdy inwestorzy preferują średnie spółki względem dużych jest oznaką zwiększającej się dominacji rynków akcji nad walutą dolar / jen. Jest to merytorycznie uzasadnione. Preferowanie mniejszych spółek to oznaka większej skłonności do ryzyka i co za tym idzie pozbywanie się dolara, czy to w postaci obligacji amerykańskich czy wymiany na inną walutę. Największe jednak znaczenie dla predykcji tego spreadu ma opóźniona o 2 miesiące zmiana indeksu S&P400. Ujemne zmiany tego indeksu w czasie t-3 oznaczają wzrost spreadu S&P500 – Dolar / Jen.

5.7.2. Analiza skuteczności modeli probitowych.

Z zaprezentowane wyników strategii dla poszczególnych spreadów można wywnioskować, iż wybrane modele probitowe średnio nie są w stanie pobić strategii pasywnej polegającej na zakupie obu składników spreadu w równych wielkościach. Strategia 2, której naturalnym benchmarkiem jest strategia pasywna, uzyskała wskaźnik stopa zwrotu / ryzyko wyższy od strategii pasywnej tylko w przypadku spreadu S&P500 – Dolar / Jen.

Jednak celem dla którego przeprowadzono analizę strategii cząstkowych była budowa strategii głównej. Wyniki tej ostatniej są już zdecydowanie bardziej zadowalające.

Strategia 2, którą należy porównywać ze strategią pasywną, okazała się mieć wyższy wskaźnik stopa zwrotu / ryzyko oraz skumulowaną stopę zwrotu i podobną wartość odchylenia standardowego. W kolejnym porównaniu strategia 3, którą należy porównywać ze strategią momentum 1 oraz momentum 2 wypadła zdecydowanie lepiej w kategorii stopa zwrotu / ryzyko niż strategia momentum 1 i jednocześnie gorzej niż strategia momentum 2. Jeżeli jednak byśmy uśrednili wyniki strategii momentum 1 i momentum 2 to wówczas model probitowy zasilany strategią 3 wypadła zdecydowanie lepiej przewyższając konkurenta o 3,21 pkt w kategorii stopa zwrotu / ryzyko. Ostatnie porównanie, na które należy zwrócić uwagę to strategia probitowa o numerze 1 oraz strategia momentum 3. W tym wypadku można uznać bezapelacyjną dominację strategii momentum 3, która okazała się lepsza od strategii 1 w kategorii stopa zwrotu / ryzyko aż o prawie 12 pkt.

Warto jednak zauważyć, iż strategii modeli probitowych miały bardzo zbliżone wskaźniki stopy zwrotu, jednak zauważalne różnice można dostrzec we wskaźnikach odchylenia standardowego, co wynika ze specyfiki danej strategii. Z wykresu 1 na uwagę zwraca bardzo wyraźny i łagodny trend wzrostowy dla strategii 3. Analizując strategię momentum należy zauważyć, iż w badanym okresie tj. od 1/2002 do 5/2009 występowało zjawisko kontynuacji stóp zwrotu²⁸. Dodatkowo było to zauważalne w dwóch kierunkach. Zarówno instrument, który w poprzednim miesiącu uzyskał najwyższą stopę zwrotu, zazwyczaj w kolejnym uzyskiwał również najwyższą stopę zwrotu, jak instrument który w poprzednim miesiącu uzyskał najniższą stopę zwrotu, zazwyczaj w kolejnym uzyskiwał również najniższą stopę zwrotu.

5.7.3. Analiza kryteriów dobroci modeli probitowych.

Analizując kryteria dobroci, można równocześnie analizować poszczególne modele. Nastąpiła bowiem taka sytuacja, iż zawsze modelowi 1 odpowiadało kryterium 1, modelowi 2 kryterium 2 i modelowi 3 kryterium 3. Najlepszym kryterium pod względem wskaźnika stopa zwrotu / ryzyko okazało się kryterium 1, za którym stoi iloraz szans oraz dodatkowo najlepszy model z rankingu łącznego modeli. Różnice jednak między Kryterium 1 i kryterium 3 są na tyle

²⁸ http://www.nbp.pl/publikacje/bank_i_kredyt/2006_08/szyszka.pdf

niewielkie, iż można założyć, że to badanie potwierdziło wyniki badania nad spreadem Wig20 – sWig80, w którym różnica między oboma kryteriami była niewielka²⁹.

5.7.4 Analiza istotności zmiennych opisujących spready.

Przeprowadzona analiza wyróżniła zmienne, które są najbardziej istotne we wszystkich 3 modelach. Okazało się, że nie zawsze najbardziej istotna zmienna z testu Simsa musi być najbardziej istotna dla modelu probitowego. Kolejnym wnioskiem płynącym z tego badania, jest zjawisko polegające na nietrwałości relacji danej zmiennej względem zmiennej opisywanej. Zjawisko to mierzone skumulowana stopą zwrotu dla danej strategii ukazuje, zdecydowanie niższą stopę zwrotu w okresie testowym.

5.7.5. Analiza problemów poruszonych na wstępie rozdziału.

Przeprowadzone badanie miało dać odpowiedź na pytanie czy krótkoterminowe odchylenia w stopach zwrotu na spreadzie między Złoto – S&P 500, Złoto – Dolar/Jen oraz S&P 500 – Dolar/Jen mogą być lepiej wyjaśniane przez następujące metody:

- ✓ model probitowy
- ✓ strategię momentum
- ✓ strategię pasywną

Analiza wyników wykazała, że model probitowy jest skuteczniejszy niż strategia pasywna. Porównując uśrednione wyniki strategii probitowych oraz strategii momentum należy stwierdzić, iż skuteczniejsze są portfele inwestycyjne oparte na strategii momentum.

Analiza kryteriów dobroci modeli probitowych wykazała, iż kryterium 1 najlepiej opisuje odchylenia na spreadzie Złoto – S&P 500, Złoto – Dolar/Jen oraz S&P 500 – Dolar/Jen. Kryterium to zawiera model, który jest preferowany pod względem ilorazu szans oraz rankingu łącznego.

Na podstawie wyników strategii głównej należy stwierdzić, iż stosowanie dywersyfikacji portfela nie poprawia stosunku stopa zwrotu / ryzyko. Okazuje się, bowiem, iż strategię oparte

²⁹ Dodatkowo w tym badaniu do kryterium 1 dołączony został optymalny model z rankingu łącznego co może nieco zniekształcić porównanie obu badań na kryterium dobroci modelu.

tylko na jednym instrumencie, jakim jest strategia 3, miały o około 5 pkt lepszy wskaźnik stopa zwrotu / ryzyko niż zdywersyfikowane strategie 1 oraz 2.

Zgodnie z przewidywaniami przedstawiają się wyniki badania dotyczącego wpływu zmian kursów walut na wyniki strategii. Okazało się, że dodanie kolejnego czynnika ryzyka jakim są zmiany kursu walutowego, w tym przypadku dolara względem polskiej złotówki, powoduje wzrost wariancji dla każdej ze strategii w ramach strategii głównej.

W toku badań nad istotnością zmiennych w modelach probitowych okazało się, że dla poszczególnych spreadów można wyróżnić zmienne w danych modelach, które w istotny sposób prognozują jego kierunek. Takich zmiennych udało się znaleźć 6. Dodatkowo okazało się, że dla tych zmiennych nie zawsze miejsce w rankingu Simsa pokrywa się z miejscem na liście najistotniejszych zmiennych w modelach. Tylko w przypadku zmiennej SP400_2 stwierdzono, iż powtórzyła swoje miejsce na liście najistotniejszych zmiennych w modelach z tym, które zajęła w rankingu Simsa. Wreszcie dowiedziono, iż w większości przypadków nie są stabilne relacje oparte na jednej zmiennej mającej średnio największy wpływ na dany spread według modeli optymalnych. Wykazano to za pomocą różnicy w stopach zwrotu jaką otrzymano budując strategię opartą o daną zmienną w dwóch okresach; przed estymacją modeli i po estymacji. Jedynie zmienna Ryz_2 w modelu spreadu Złoto – Dolar / Jen okazała się być stabilna, na tyle, że skumulowana stopa zwrotu okazała się być dodatnia, jednak o ponad 50% niższa niż w okresie przed estymacją modelu.

Rozdział VI

Wykorzystanie modelu probitowego w procesie alokacji aktywów między spółki z indeksu sWig80.

6.1. Wprowadzenie i przegląd dotychczasowych badań.

Zagadnienie wykorzystania modeli dwumianowych do analizy zachowania się kursu polskich spółek giełdowych zostało już opisane w wielu pracach naukowych. Wspomniane wcześniej prace Batóg i Wawrzyniak (2004), (2005) i (2007), jak i praca Gruszczyńskiego (2002) w sposób kompleksowy i nowatorski podchodzą do powyższego tematu. Z zagranicznych prac naukowych można wymienić opracowanie Mortona i Shane (1998), którzy za pomocą szeregów czasowych sporządzonych z danych ze sprawozdań finansowych szacowali prawdopodobieństwo uzyskania nadwyżkowej stopy zwrotu przez daną spółkę. Rozważali oni czy możliwość przewidzenia nadwyżkowej stopy zwrotu jest większa dla małych spółek niż dla większych. Hipotezę tą, tłumaczyli nieefektywnością rynku. Wyniki, jakie uzyskali, nie potwierdziły jednak tej hipotezy. Ou i Penman (1989) stworzyli logitowy model analizujący sprawozdania finansowe, który był w stanie przewidzieć na jeden okres wcześniej zyski, jakie spółka zakomunikuje rynkowi. Natomiast ciekawy wniosek wysnuli Holthausen i Larcer (1992), dowodząc, że wyższe zyski można uzyskać omijając analizę sprawozdań finansowych, a jedynie opierając się na nadwyżkowych stopach zwrotu i zmiennych tj. rozmiar spółki i innych zmiennych określających ryzyko inwestycji w papiery danej spółki. Z kolei Bernard, Thomas i Wahlen (1997) zbadali strategię przedawnioną przez Holthausena i Larcera i dowiedli, że ponadprzeciętne zwroty pojawiają się, aby zrekompensować ryzyko. Wreszcie warto wspomnieć o pracy Arendarskiego (2009), w której autor za pomocą modelu probitowego prognozuje zmiany wartości przedsiębiorstw z branży spożywczej na podstawie zmian wskaźników finansowych.

U podstaw wyżej opisanych prac, kryje się teoria półsilnej efektywności rynków, która mówi, że niemożliwe jest wytypowanie na podstawie dostępnych informacji strategii inwestycyjnych, dających stopy zwrotu istotnie wyższe, niż stopy wynikające z przyjętego modelu wyceny lub odpowiedniego benchmarku. Oznacza to, że eksperymenty symulacyjne polegające na testowaniu strategii inwestycyjnych dla danych historycznych także nie powinny

wyłączyć żadnej, dającej ponadprzeciętną stopę zwrotu³⁰. Zdaniem A. Szyszki [2003] struktura inwestorów na rynku może mieć zasadnicze znaczenie dla uzyskania średniej formy efektywności. Jeśli grupa inwestorów profesjonalnych, nieustannie przetwarzających wszystkie nadchodzące informacje i niezwłocznie dokonujących transakcji na ich podstawie, będzie odpowiednio duża, wtedy swoim aktywnym działaniem sprawia oni, że wykorzystywane przez nich informacje szybko znajdą odzwierciedlenie w kursach papierów wartościowych. Jeśli natomiast rynek zdominowany byłby przez wielu indywidualnych graczy, którzy nie są w stanie zebrać wszystkich dostępnych informacji i po uprzedniej ich analizie dokonać szybkich transakcji, wówczas średnia efektywność nie koniecznie musi się pojawić. Właśnie tę okoliczność autor w tej pracy będzie testować.

Pewnym wyjaśnieniem pól silnej nieefektywności rynku jest model DHS, w którym nadmierna pewność inwestorów pociąga za sobą zbyt silną reakcję pociąga za sobą zbyt silną reakcję na informację prywatną, zaś zniekształcenia związane z niewłaściwą atrybucją wydarzeń są odpowiedzialne za niedoceniając znaczenia informacji publicznych. Takie zachowanie inwestorów może powodować występowanie krótkoterminowych trendów oraz długookresowych odwrotności w kształtowaniu się stóp zwrotu³¹. Co może być przyczyną sytuacji, w której gracze rynkowi reagują w sposób niepełny w momencie opublikowania wyników finansowych, ponieważ większą wagę przywiązują do swojej wcześniejszej oceny danej firmy niż do nowego pojedynczego publicznego sygnału. Dopiero wraz z napływem kolejnych informacji ich opinia ulega zmianie.

Powyższe rozważania były natchnieniem dla powstania tego badania. Autor uważa, że zmiany wielu wskaźników analizy finansowej tworzą swego rodzaju zagadkę dla inwestorów, którzy w pierwszej chwili nie są w stanie odpowiednio zareagować, wycenić spółki. Dodatkowo autor wierzy, że te zmiany różnych wskaźników tworzą pewną sekwencję rozwojową dla danej spółki. Tak, więc z jednej strony model może prognozować przyszły kurs spółki za okres między publikacjami wyników, a z drugiej strony może być dobrym predyktorem przyszłych wyników finansowych. W prezentowanym opracowaniu przedmiotem badań będą małe spółki, gdyż wydaje się zasadne twierdzenie Mortona i Shane, że w przypadku spółek o mniejszej

³⁰ Czekaj J., Woś W., Tarnowski J. [2001] *Efektywność giełdowego rynku akcji w Polsce*, Wydawnictwo PWN, Warszawa, s. 112.

³¹ Szyszka A. [2003] *Efektywność Giełdy Papierów Wartościowych w Warszawie na tle rynków dojrzałych*, Wydawnictwo Uniwersytetu Ekonomicznego Poznaniu, Poznań, s. 85

kapitalizacji rynek jest mniej efektywny. Mniejsze spółki, są, bowiem rzadziej analizowane przez analityków i co za tym idzie inwestorzy mają mniejszą wiedzę na temat rzeczywistej kondycji finansowej danej spółki. Stosując model probitowy do prognozowania wartości małych spółek względem ich benchmarku, autor podejrzewa, że uda się uzyskać lepsze wyniki, niż stosując strategię pasywną względem indeksu sWig80. Dodatkowym asumptem dla przeprowadzenia badania stało się stworzenie koncepcji Probit Portfolio, która według wiedzy autora zostanie zaprezentowana po raz pierwszy w pracy naukowej na poziomie rozprawy doktorskiej.

6.2. Cel pracy, hipotezy badawcze

Celem tej części pracy była odpowiedź na pytanie, czy model probitowy może być skutecznym³² narzędziem w procesie budowy struktury portfela na podstawie zmian wskaźników finansowych.

Dodatkowo autor odpowie na pytania:

- które z kryteriów dobroci modelu okaże się najskuteczniejsze
- które czynniki dotyczące kondycji finansowej przedsiębiorstwa determinują jego przyszły wzrost lub spadek wartości w stosunku do indeksu w skład którego wchodzi.,
- czy strategia inwestycyjna oparta o model probitowy jest w stanie uzyskać wyższą stopę zwrotu, niż strategia oparta o metodę momentum.

6.3. Metodologia i wyniki badań nad wykorzystaniem modelu probitowego.

W celu weryfikacji hipotezy badawczej autor wyselekcjonował 22 spółki z indeksu sWig80, tabela 67. Każda ze spółek posiada od 3 do 4 obserwacji, łącznie daje 69 obserwacji. Jako główne kryterium doboru spółek do zbioru testowego autor przyjął dostępność wszystkich danych, które były potrzebne do obliczenia wskaźników analizy finansowej.

Autor zdecydował się na badanie zmian wskaźników, gdyż sam poziom danego wskaźnika nie jest wskazówką dotyczącą przyszłego zachowania się kursu. Autor uważa, że kierunek zmiany i jej wartość są skutecznym prognostykiem przyszłej wartości spółki.

³² W danej sytuacji model probitowy będzie skuteczny, gdy stopa zwrotu uzyskana z portfela spółek wybranych za pomocą jego wskazań, okaże się wyższa niż strategia pasywna. W tym przypadku strategią pasywną jest stopa wzrostu z indeksu sWig80.

Spośród tradycyjnych wskaźników analizy finansowej, autor starał się wyselekcjonować takie, które będą posiadać dużą moc prognostyczną. Dodatkowo autor korzystał z badań poprzednich lat. W ten sposób użyto wskaźników zaprezentowanych w pracy Arendarskiego oraz zaprezentowano kilka nowych.

Wśród wskaźników, które zostały wykorzystane w pracy Arendarskiego znajdują się:

- Zmiany wskaźnika Ebitda / Aktywa
- Zmiany wskaźnika Sprzedaż / Aktywa
- Zmiany wskaźnika Zysk Netto / Sprzedaż
- Zmiany wskaźnika Przepływy z działalności operacyjnej / Kapitał własny
- Zmiany wskaźnika Kapitalizacja - Przepływy z działalności operacyjnej
- Zmiany wskaźnika Kapitał własny / Przepływy netto
- Zmiany wskaźnika Cena 1 akcji / Wartość księgowa 1 akcji
- Zmiany wskaźnika Zysk Operacyjny / Sprzedaż

Tabela 67. Wybrane spółki z indeksu sWig80

1	AtmGrupa	12	Koelner
2	AzotyTarnów	13	Kofola
3	Barlinek	14	Lentex
4	Comarch	15	MostExp
5	Dębica	16	Nepentes
6	ElstarOil	17	Ponar
7	Erbud	18	Próchnik
8	Famur	19	QumakSeqom
9	Hawe	20	Ruch
10	Hygienika	21	Śnieżka
11	IBSystem	22	Wielton

Źródło: Opracowanie własne.

Dodatkowo autor podał 5 wskaźników, które jego zdaniem mają dużą moc predykcyjną. Lista tych wskaźników wygląda następująco:

1. Zmiany wskaźnika Przepływy z działalności operacyjnej / Sprzedaż. Zmiany tego wskaźnika informują o różnicy między dodatnimi przepływami gotówkowymi z działalności operacyjnej a przychodami ze sprzedaży będących wielkością memoriałową. Wzrost tego wskaźnika przy niezmiennym poziomie sprzedaży może być symptomem poprawy procesu ściągania należności od kontrahentów, co powinno mieć pozytywny wpływ na rotację kapitału. Jednak z drugiej strony spadek wartości tego wskaźnika, przy niezmiennym poziomie przepływów gotówkowych z działalności operacyjnej, świadczy o zwiększonym popycie na usługi/produkty spółki, co jest również dobrym sygnałem dla inwestorów. Dodatkowo nie można wykluczyć zmian obu wartości. Wnioski te, sprawiają, że trudno jest w sposób zdecydowany ustalić optymalnego kierunku dla wskaźnika. Taka sytuacja implikuje konieczność zastosowania bardziej wyrafinowanych narzędzi analitycznych do oceny wpływu kierunku i wartości wskaźnika na przyszły kierunek ceny względem indeksu sWig80.
2. Zmiany Przepływów z działalności operacyjnej oraz zmiany Przepływów netto. Wartość ta, jest przez inwestorów bardzo uważnie śledzona. Są to bowiem wartości które, świadczą o tym, że spółka oprócz generowania przychodów ze sprzedaży, również jest zasilana w gotówkę, potrzebną do działalności przedsiębiorstwa. Szczególnie w trudnych czasach, znaczenie przepływów pieniężnych jest doceniane. Bardzo często, jednym z kryterium alokacji aktywów w daną spółkę jest ilość gotówki jaką posiada z działalności operacyjnej lub zmiany tej wartości. Podobnie sytuacja wygląda ze wskaźnikiem przepływów netto, który informuje o tym jaki jest łączny bilans przepływów gotówkowych. Wydaje się, że dodatnie wartości obu wskaźników są dobrym prognostykiem dla spółki.
3. Zmiany wskaźnika $\text{Zysk netto} + \text{Amortyzacja} / \text{Liczba wyemitowanych akcji}$. Zmiany wskaźnika $\text{Zysk netto} / \text{Liczba wyemitowanych akcji}$. Zmiany wskaźnika $\text{Ebitda} / \text{Liczba wyemitowanych akcji}$. Cała grupa wskaźników informuje o tym, ile jego spółka zarabia na jedną akcje. Wskaźniki tego typu oddają sytuację dotyczącą zmian w zyskach spółki, jeśli liczba akcji pozostanie bez zmian. Często jednak spółki emitują akcje w trakcie roku i wówczas te wskaźniki nabiera, dodatkowej wartości. Wydaje się że pozytywne (dodatnie) zmiany tego wskaźnika są pożądaną sytuacją dla inwestorów.

4. Rentowność operacyjna. Wskaźnik ten ma dużą wartość dla rynków kapitałowych, gdyż informuje o zyskowności spółki w jej głównym biznesie. Niewątpliwie więc pozytywne zmiany tego wskaźnika odgrywają ważną rolę w analizie zdolności spółki do wzrostu jej wartości.
5. Zmiany wskaźnika Przychody - Zobowiązania krótkoterminowe. Jest to autorski wskaźnik, którego pożądany kierunek jest trudno ustalić. Jest to pozytywna tendencja dla spółki gdy przychody rosną, natomiast nie można jednoznacznie stwierdzić, że korzystnym symptomem jest spadek zobowiązań. Z jednej strony spadek zobowiązań może świadczyć o tym, że spółka nie ma problemów płynnościowych i na czas reguluje swoje zobowiązania, z drugiej strony spłata zobowiązań to utrata gotówki, która mogłaby być ulokowana w płynnych aktywach zwiększających przychody finansowe spółki. Zasadne wydaje się więc użyć modelu probitowego do rozwiązania tej rozbieżności.

Lista wskaźników analizy finansowej, tabela 68, zawiera 16, zdaniem autora najbardziej przydatnych zmiennych do oceny przyszłej wartości spółki. Wskaźniki te posłużyły jako zmienne objaśniające.

Tabela 68. Wykaz zmiennych użytych do badania.

Symbol zmiennej	Zmienna (zmiana z okresu t-1 do okresu t)
Ebitda_Aktywa	Zmiany wskaźnika <i>Ebitda / Aktywa</i>
Sprzedaz_Aktywa	Zmiany wskaźnika <i>Sprzedaż / Aktywa</i>
PrzepOp_Sprzedaz	Zmiany wskaźnika <i>Przepływy z działalności operacyjnej / Sprzedaż</i>
Kapit_PrzepOp	Zmiany wskaźnika <i>Kapitalizacja - Przepływy z działalności operacyjnej</i>
Cena1_WK1	Zmiany wskaźnika <i>Cena 1 akcji / Wartość księgowa 1 akcji</i>
ZyskNe_Sprzedaz	Zmiany wskaźnika <i>Zysk Netto / Sprzedaż</i>
PrzepOp_KapW1	Zmiany wskaźnika <i>Przepływy z działalności operacyjnej / Kapitał własny</i>
KapW1_PrzepNe	Zmiany wskaźnika <i>Kapitał własny / Przepływy netto</i>
ZyskOp_Aktywa	Zmiany wskaźnika <i>Zysk Operacyjny / Sprzedaż</i>
PrzepOp	Zmiany Przepływów z działalności operacyjnej
PrzepNe	Zmiany Przepływów netto
CF1	Zmiany wskaźnika <i>Zysk netto + Amortyzacja / Liczba wyemitowanych akcji</i>
RentowOp	Zmiany Rentowności operacyjnej
Przychody_ZobKr	Zmiany wskaźnika <i>Przychody - Zobowiązania krótkoterminowe</i>
ZyskNe1	Zmiany wskaźnika <i>Zysk netto / Liczba wyemitowanych akcji</i>
Ebitda1	Zmiany wskaźnika <i>Ebitda / Liczba wyemitowanych akcji</i>

Źródło: Opracowanie własne.

Badanie wskaźników analizy finansowej obejmowało sprawozdania finansowe spółek za okres od II kwartału 2008 roku do II kwartału 2009 roku. Analizowano zmiany wskaźników z okresu na okres. W ten sposób każdej spółce w okresie treningowym przypisano 3 obserwacje i powstał zbiór treningowy³³ w taki sposób, że:

1 obserwacja –zmiana wskaźników między III kwartałem 2008, a IV kwartałem 2008

2 obserwacja- zmiana wskaźników między VI kwartałem 2008, a I kwartałem 2009

3 obserwacja- zmiana wskaźników między I kwartałem 2009, a II kwartałem 2009

Natomiast zbiór testowy³⁴ tworzyła obserwacja 4 w taki sposób, że:

4 obserwacja- zmiana wskaźników między II kwartałem 2009, a III kwartałem 2009

³³ Zbiór treningowy – obserwacje wykorzystane do budowy modelu

³⁴ Zbiór testowy - obserwacje poza okresem estymacji modelu

Zmiany wskaźników posłużyły do modelu jako zmienne objaśniające, natomiast zmienną objaśnianą była informacja czy kurs danej spółki w danym okresie osiągnął stopę zwrotu wyższą czy niższą od benchmarku jakim była stopa zwrotu z indeksu sWig80.

Estymacja modelu.

Analizowany model będzie miał postać:

$$Y_{i,t} = \beta_1 + \beta_2 X_{i,t-1} + \dots + \beta_k X_{k,t-1} + u_i$$

gdzie,

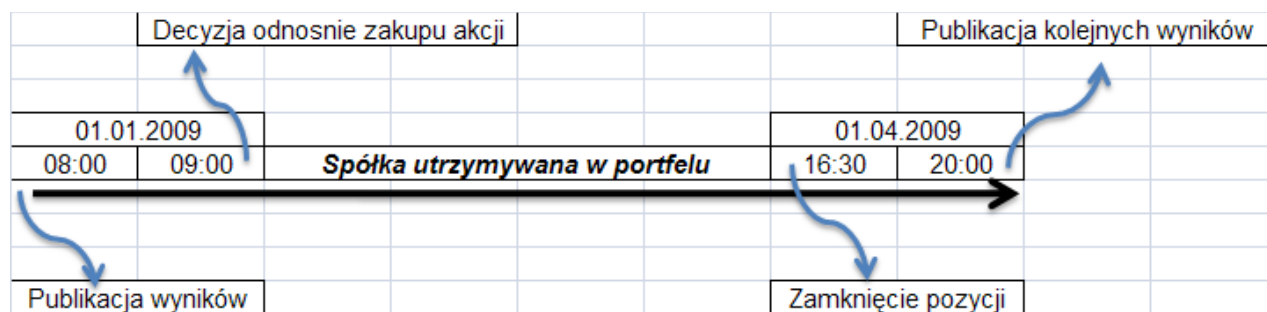
X – zmienne objaśniające

$Y_{i,t} = 1$, jeśli różnica w ujęciu procentowym między zmianą wartości spółki i w czasie t a sWig80 w czasie t będzie dodatnia,

$Y_{i,t} = 0$, jeśli różnica w ujęciu procentowym między zmianą wartości spółki i w czasie t a sWig80 w czasie t będzie ujemna,

Ważną kwestią podlegającą wyjaśnieniu jest moment zawarcia transakcji i moment zamknięcia transakcji. Jest on równoważny z okresem wyliczania stopy zwrotu z inwestycji. Czyli zmiana stopy zwrotu w tym okresie decyduje czy dana obserwacja zostanie zakwalifikowana do zbioru uczącego się jako „1” czy jako „0”. Diagram poniżej obrazuje momenty kluczowe dla strategii. Na diagramie umieszczono przykładowe godziny i daty. Można zauważyć, strategia jest możliwa do zastosowania w praktyce, gdyż inwestor podejmuje decyzje już po reakcji rynku na dane finansowe. Jeśli wyniki finansowe podane są przed sesją, wówczas inwestor może kupić akcję danej spółki po cenie otwarcia. Następnie akcje spółki są trzymane do momentu, ostatniej sesji przed podaniem następnych wyników. Na zakończenie tej sesji inwestor sprzedaje akcję.

Diagram 1. Przykładowy przebieg procesu zakupu i sprzedaży akcji.



Źródło: Opracowanie własne.

Przystąpiono do estymacji modeli ekonometrycznych prognozujących zmianę wartości spółki. Do tego celu użyto model probitowy.

Głównym celem estymacji modeli było znalezienie po jednym modelu, który by miałby najbardziej efektywne następujące kryteria:

- o Test ilorazu wiarygodności
- o Iloraz szans wyznaczony na podstawie tabeli trafności klasyfikacji przypadków, wyznaczony zgodnie ze wzorem
- o Zmodyfikowany R-kwadrat McFaddena
- o Absolutny błąd prognozy.

Dodatkowo autor szukał modelu, który by był najbardziej efektywny pod względem autorskiego rankingu łącznego kryteriów dobroci, którego metodologie opisano w dalszym etapie pracy. Uzasadnienie zastosowania powyższych kryteriów zostało opisane w rozdziale 3.4.

W porównaniu z poprzednimi obszarami badawczymi postanowiono dokonać wymiany jednego z kryteriów. Jako, że we wcześniejszych badaniach modele wybierane według kryterium Akaike'a nie okazały się być lepsze od modeli wybieranych według pozostałych kryteriów, dokonano zamiany tego kryterium na zmodyfikowany R-kwadrat McFaddena. Kryterium to jest obliczane według wzoru:

$$Pseudo R^2 = 1 - (\ln L_{MP} / \ln L_{MZ})$$

gdzie:

$\ln L_{MP}$ - jest logarytmem funkcji wiarygodności dla modelu pełnego,

$\ln L_{MZ}$ – jest logarytmem funkcji wiarygodności dla modelu zredukowanego do wyrazu wolnego³⁵. Miarę efektywności tego kryterium można zapisać jako: $Pseudo R^2 \Rightarrow \max$

Następnie dokonano estymacji modeli w oparciu o metodę algorytmu regresji krokowej wstecznej.

Ostatecznie stworzono 16 modeli. Modele w tabeli 69 przedstawiają kryteria poszczególnych modeli probitowych na podstawie metody regresji krokowej wstecznej.

Tabela 69. Prezentacja parametrów modeli za pomocą algorytmu regresji krokowej.

Model	Najmniej istotna zmienna	Liczba przypadków poprawnej predykcji	Test ilorazu wiarygodności [wartość p]	Średni błąd absolutny	McFadden R-kwadrat
1	PrzepOp_Sprzedza	69,60%	0,2062	0,36818	0,215071
2	Ebitda_Aktywa	71,00%	0,1605	0,36838	0,214935
3	ZyskNe_Sprzedaz	69,60%	0,1216	0,36855	0,214645
4	ZyskOp_Aktywa	71,00%	0,0908	0,36923	0,213584
5	Cena1_WK1	69,60%	0,0648	0,36947	0,213006
6	CF1	71,00%	0,0446	0,37008	0,212252
7	ZyskNe1	68,10%	0,0316	0,37142	0,209173
8	KapWl_PrzepNe	66,70%	0,0306	0,37928	0,195011
9	Ebitda1	58,00%	0,0864	0,40668	0,146334
10	RentowOp	59,40%	0,0623	0,40893	0,142152
11	Sprzedaz__Aktyw	59,40%	0,0434	0,41187	0,137373
12	PrzepNe	62,30%	0,0443	0,41972	0,120502
13	PrzepOp_KapWl	62,30%	0,0272	0,42151	0,115854
14	PrzepOp	58,00%	0,0242	0,43177	0,099715
15	Przychody_ZobKr	66,70%	0,0281	0,44428	0,075602
16	-	63,80%	0,0289	0,4608	0,05

Źródło: Opracowanie własne.

³⁵ Gruszczyński M. [2009], *Ekonometria ...*, op. cit., s. 173 - 179

Numer w kolejnych modelach oznacza liczbę kolejnych estymacji metodą regresji krokowej wstecznej, im większy numer tym więcej usunięto zmiennych najmniej istotnych. Po każdej takiej estymacji najmniej istotna zmienna została usunięta.

Następnie stworzono rankingi modeli według wyżej omawianych kryteriów dobroci modelu. W ten sposób powstały rankingi według następujących kryteriów:

- Ranking 1 - Liczba przypadków poprawnej predykcji
- Ranking 2 - Test ilorazu wiarygodności
- Ranking 3 - Zmodyfikowany R-kwadrat McFaddena
- Ranking 4 - Średni błąd absolutny

Modele były oceniane w taki sposób, że punkty w rankingu były przydzielane według reguły:

$$(x-k+1),$$

gdzie:

x – ilość modeli w rankingu, k – miejsce modelu w rankingu.

W ten sposób najbardziej efektywny modelu otrzymał 16 punktów, kolejny model otrzymał 15 punktów. Obliczenia zawiera tabela 70. Ranking łączny powstał w taki sposób, że punkty każdego z modeli we wszystkich kategoriach zostały zsumowane. Obliczenia dla najbardziej efektywnych modeli przedstawia tabela 71.

Po analizie dopasowań wszystkich modeli wybrano 3 modele.

- Model 1 - model 2 był efektywny zarówno pod względem liczba przypadków poprawnej predykcji, jak i rankingu łącznego ,
- Model 2 - model 14 był efektywny pod względem testu ilorazu wiarygodności,
- Model 3 - model 1 był najbardziej efektywny zarówno pod względem średniego błędu absolutnego, jak i R-kwadrat McFadden.

Tabela 70. Modele probitowe wg. poszczególnych kryteria dobroci modelu.

Model	Liczba przypadków poprawnej predykcji	Model	Test ilorazu wiarygodności [wartość p]	Model	Średni błąd absolutny	Model	McFadden R-kwadrat
2	71,00%	14	0,024	1	0,368	1	0,215
4	71,00%	13	0,027	2	0,368	2	0,215
6	71,00%	15	0,028	3	0,369	3	0,215
1	69,60%	16	0,029	4	0,369	4	0,214
3	69,60%	8	0,031	5	0,369	5	0,213
5	69,60%	7	0,032	6	0,370	6	0,212
7	68,10%	11	0,043	7	0,371	7	0,209
8	66,70%	12	0,044	8	0,379	8	0,195
15	66,70%	6	0,045	9	0,407	9	0,146
16	63,80%	10	0,062	10	0,409	10	0,142
12	62,30%	5	0,065	11	0,412	11	0,137
13	62,30%	9	0,086	12	0,420	12	0,121
10	59,40%	4	0,091	13	0,422	13	0,116
11	59,40%	3	0,122	14	0,432	14	0,100
9	58,00%	2	0,161	15	0,444	15	0,076
14	58,00%	1	0,206	16	0,461	16	0,051

Źródło: Opracowanie własne.

Tabela 71. Ranking łączny dla najlepszych siedmiu modeli probitowych

Model	Liczba przypadków poprawnej predykcji	Test ilorazu wiarygodności [wartość p]	Średni błąd absolutny	McFadden R-kwadrat	Punkty
2	16	2	15	15	48
1	13	1	16	16	46
4	16	4	13	13	46

c.d. Tabela 71.					
6	16	8	11	11	46
3	12	3	14	14	43
5	11	6	12	12	41
7	10	11	10	10	41

Źródło: Opracowanie własne.

Oszacowania wybranych modeli przedstawiają się następująco:

Model 1

Estymacja Probit, wykorzystane obserwacje 1-69

Zmienna zależna: $Y_{i,t}$

	współczynnik	błąd standardowy	t-Studenta	wartość p	
const	0,0628075	0,21649	0,2901	0,7717	
Ebitda_Aktywa	-2,22351	13,4053	-0,1659	0,8683	
Sprzedaz__Aktyw	2,95679	2,23396	1,324	0,1856	
Kapit_PrzepOp	-2,63E-06	1,71E-06	-1,544	0,1225	
Cena1_WK1	-0,116355	0,322665	-0,3606	0,7184	
ZyskNe_Sprzedaz	-0,169989	0,587227	-0,2895	0,7722	
PrzepOp_KapW1	0,866581	0,94144	0,9205	0,3573	
KapW1_PrzepNe	3,00E-06	3,02E-06	0,9937	0,3204	
ZyskOp_Aktywa	-1,0743	5,14372	-0,2089	0,8346	
PrzepOp	-6,22E-06	6,24E-06	-0,9971	0,3187	
PrzepNe	9,09E-06	5,61E-06	1,621	0,105	
CF1	-0,0066208	0,0142441	-0,4648	0,6421	
RentowOp	0,0346136	0,0548394	0,6312	0,5279	
Przychody_ZobKr	-6,94E-06	3,51E-06	-1,978	0,048	**
ZyskNe1	0,354757	0,29232	1,214	0,2249	
Ebitda1	-0,721259	0,422425	-1,707	0,0877	*

McFadden R-kwadrat 0,214935 Skorygowany R-kwadrat -0,123772

Liczba przypadków 'poprawnej predykcji' = 49 (71,0%)

Test ilorazu wiarygodności: Chi-kwadrat(15) = 20,3064 [0,1605]

Model 2

Estymacja Probit, wykorzystane obserwacje 1-69

Zmienna zależna: $Y_{i,t}$

	współczynnik	błąd standardowy	t-Studenta	wartość p	
const	-0,133073	0,159075	-0,8365	0,4028	
Kapit_PrzepOp	-2,70E-06	1,08E-06	-2,491	0,0127	**
PrzepOp	-2,96E-06	2,01E-06	-1,474	0,1403	
Przychody_ZobKr	-4,86984e-06	2,83E-06	-1,723	0,0849	*

McFadden R-kwadrat 0,099715 Skorygowany R-kwadrat 0,015039

Liczba przypadków 'poprawnej predykcji' = 40 (58,0%)

Test ilorazu wiarygodności: Chi-kwadrat(3) = 9,42081 [0,0242]

Model 3

Estymacja Probit, wykorzystane obserwacje 1-69

Zmienna zależna: $Y_{i,t}$

	współczynnik	błąd standardowy	t-Studenta	wartość p
const	0,0635475	0,216468	0,2936	0,7691
Ebitda_Aktywa	-1,8688	13,729	-0,1361	0,8917
Sprzedaz__Aktyw	2,90794	2,25909	1,287	0,198
PrzepOp_Sprzeda	-0,0724047	0,637565	-0,1136	0,9096
Kapit_PrzepOp	-2,66E-06	1,73E-06	-1,541	0,1234
Cena1_WK1	-0,111049	0,32628	-0,3403	0,7336
ZyskNe_Sprzedaz	-0,19118	0,615248	-0,3107	0,756
PrzepOp_KapW1	0,915543	1,03497	0,8846	0,3764
KapW1_PrzepNe	3,00E-06	2,99E-06	1,006	0,3145
ZyskOp_Aktywa	-1,18618	5,24351	-0,2262	0,821
PrzepOp	-5,91E-06	6,71E-06	-0,88	0,3789
PrzepNe	9,10E-06	5,59E-06	1,628	0,1034
CF1	-0,00667636	0,0142766	-0,4676	0,64
RentowOp	0,0356611	0,0556263	0,6411	0,5215

c.d. Model 3.

Przychody_ZobKr	-6,93E-06	3,51E-06	-1,977	0,0481	**
ZyskNe1	0,363193	0,302212	1,202	0,2294	
Ebitda1	-0,737672	0,44736	-1,649	0,0992	*

McFadden R-kwadrat 0,215071 Skorygowany R-kwadrat -0,144805

Liczba przypadków 'poprawnej predykcji' = 48 (69,6%)

Test ilorazu wiarygodności: Chi-kwadrat(16) = 20,3192 [0,2062]

Warto tutaj nadmienić fakt, iż otrzymane modele zawierają zmienne nieistotne. Jednak jak już wspomniano na początku rozdziału; głównym celem estymacji było znalezienie modeli, które są efektywne pod względem wymienionych wcześniej kryteriów.

6.4. Metodologia strategii momentum.

Pierwszy etap.

Dla wszystkich zmiennych objaśniających przeprowadzono identyczną procedurę, która zostanie zilustrowana na przykładzie zmiennej Cena1_WK1.

Obserwację z zbioru treningowego posortowano według maksymalnych wartości tej zmiennej. Uwagę zwrócono na 10 najwyższych obserwacji i 10 najniższych obserwacji tej zmiennej. Autor bowiem sprawdził ile razy w tych ekstremalnych obserwacjach zmienna binarna przyjęła wartość 1. W badanym przykładzie zauważono, że zmienna Cena1_WK1 posiadała tylko jedną obserwację, która miała wartość 1 zmiennej binarnej zbiorze maksymalnych wartości oraz 4 obserwację w zbiorze minimalnych wartości. Można przyjąć więc, wśród 10 spółek / obserwacji, które osiągały największe przyrosty zmiennej Cena1_WK1 tylko jedna spółka / obserwacja osiągnęła stopę zwrotu wyższą niż indeks sWig80. Analogicznie, wśród 10 spółek / obserwacji, których zmiany zmiennej Cena1_WK1 osiągały wartości najniższe, cztery spółki / obserwacje osiągnęły stopę zwrotu wyższą niż indeks sWig80.

Tak, więc nasuwa się spostrzeżenie, iż ekstremalnie najwyższe wartości tej zmiennej są dobrym prognostykiem niższej stopy zwrotu danej spółki w odniesieniu do indeksu sWig80. Takie prognozy w zbiorze treningowym sprawdziłyby się w 90% procentach.

Autora interesowały sytuację (sytuacja momentum), w których, w zbiorach ekstremalnych zmienna binarna przyjęła wartość 1 więcej niż siedem razy lub mniej niż trzy razy. Powyższy algorytm zastosowano do wszystkich zmiennych. Otrzymano w rezultacie 3 takie sytuacje, które przedstawia tabela 72.

Tabela 72. Wybrane zmienne do analizy na zbiorze testowym wraz z ich sytuacjami momentum.

Zmienna	Sytuacja momentum
Kapit_PrzepOp	2 razy wartość „1” zmiennej binarnej dla najwyższych 10 wartości danej zmiennej
Cena1_WK1	1 raz wartość „1” zmiennej binarnej dla najwyższych 10 wartości danej zmiennej
PrzepNe	2 razy wartość „1” zmiennej binarnej dla najniższych 10 wartości danej zmiennej

Źródło: Opracowanie własne.

Następnym krokiem było zastosowanie wyników ze zbioru treningowego na zbiorze treningowym. Tym razem badaniu zostały poddane tylko trzy wyżej wymienione sytuacje momentum.

Zmienną Kapit_PrzepOp posortowano według jej wartości i dla 5 najwyższych obserwacji obliczono średnią stopę zwrotu. Ze względu na to, że wysokie wartości tego wskaźnika skutkowały w zbiorze treningowym niższą stopą zwrotu od indeksu sWig80, zastosowano krótką sprzedaż dla tego teoretycznego portfela akcji.

Zmienną Cena1_WK1 posortowano według jej wartości i również dla 5 najwyższych obserwacji obliczono średnią stopę zwrotu. Także w tym przypadku zastosowano krótką sprzedaż dla tego zbioru akcji.

Zmienną Kapit_PrzepOp posortowano według jej wartości i dla odmiany dla 5 najniższych obserwacji obliczono średnią stopę zwrotu. Ponieważ niskie wartości tego wskaźnika skutkowały w zbiorze treningowym niższą stopą zwrotu od indeksu sWig80, zajęto krótką pozycję. Tabela 73 prezentuje wybrane spółki do portfela oraz wartości wskaźników analizy finansowej.

Tabela 73. Wybrane spółki i wartości zmiennych objaśniających.

Spółka	Kapit_PrzepOp	Spółka	Cena1_WK1	Spółka	PrzepNe
Comarch	2437661	Comarch	6,73	Nepentes	-9417
Ruch	311858	Wielton	1,09	ElstarOil	-12979
Erbud	221900	Erbud	1,00	Comarch	-51138
AzotyTarnów	210224	Hawe	0,94	Barlinek	-51138
Hawe	192351	Nepentes	0,76	AzotyTarnów	-117677

Źródło: Opracowanie własne.

6.5. Wyniki badań. Koncepcja Probit Portfolio

Następnym krokiem była analiza wyników otrzymanych za pośrednictwem modelu probitowego jak i strategii momentum. Tabela 74 przedstawia prognozy stóp zwrotu powyżej lub poniżej benchmarku według 3 wybranych modeli.

Wyróżnione w tabeli wartości obrazują spółki, które w przyszłym kwartale będą miały z prawdopodobieństwem powyżej 50% stopę zwrotu wyższą aniżeli indeks sWig80.

Tabela 74. Lista spółek wraz z prognozami.

Spółka	Model 1	Model 2	Model 3
AtmGrupa	0,44	0,43	0,42
AzotyTarnów	0,38	0,37	0,46
Barlinek	0,14	0,14	0,21
Comarch	0,00	0,00	0,00
Dębica	0,22	0,22	0,31
ElstarOil	0,23	0,23	0,21
Erbud	0,12	0,12	0,15
Famur	0,46	0,45	0,40
Hawe	0,35	0,35	0,24
Hygienika	0,51	0,51	0,44
IBSystem	0,46	0,45	0,44
Koelner	0,16	0,16	0,17
Kofola	0,22	0,22	0,44

c.d. Tabela 74.			
Lentex	0,53	0,53	0,46
MostExp	0,30	0,33	0,45
Nepentes	0,31	0,32	0,37
Ponar	0,35	0,35	0,53
Próchnik	0,10	0,08	0,37
QumakSeqom	0,33	0,34	0,40
Ruch	0,61	0,57	0,61
Wielton	0,35	0,35	0,28
Śnieżka	0,33	0,33	0,25

Źródło: Opracowanie własne.

Na tym etapie pracy autor zaprezentował koncepcję Probit Portfolio. Jest to metoda doboru spółek do portfela za pomocą wskazań modelu probitowego.

Konstrukcja portfela polegała na tym, że udział każdej spółki w danym portfelu jest proporcjonalny do wartości prognozy, jaka dana spółka otrzymała, w ten sposób, że:

$$W_i = Pr_i / \sum Pr, \text{ gdzie:}$$

W_i – waga w portfelu i-tej spółki

Pr_i – prognoza dla i-tej spółki

$\sum Pr$ – suma prognoz powyżej 0,5

W ten przypadku, zbudowano 3 portfele dla 3 najbardziej efektywnych modeli. Portfele te zawierają od 2 do 3 instrumentów finansowych, gdyż nałożono ograniczenia, aby prognoza była wyższa niż 0,5. Jednak w praktyce inwestor może dowolnie edytować nałożone ograniczenie lub nawet z niego zrezygnować.

Tabele 75, 76 i 77 prezentują poszczególne portfele akcji wraz z wagami i stopami zwrotu przypisanymi poszczególnym instrumentom, jak i łączną stopą zwrotu dla portfela. Następnie w tabeli 78 zaprezentowano wyniki strategii momentum.

Tabela 75. Portfel zbudowany w oparciu o model 1.

Model 1		
Spółka	Waga w portfelu poszczególnych spółek wg. metody Probit Portfolio	Stopa zwrotu skorygowana o wagę w portfelu
Ruch	0,37	-1,02%
Lentex	0,32	0,13%
Hygienika	0,31	1,24%

Stopa zwrotu z portfela	0,347%
--------------------------------	--------

Źródło: Opracowanie własne.

Tabela 76. Portfel zbudowany w oparciu o model 2.

Model 2		
Spółka	Waga w portfelu poszczególnych spółek wg. metody Probit Portfolio	Stopa zwrotu skorygowana o wagę w portfelu
Ruch	0,35	-0,96%
Lentex	0,32	0,13%
Hygienika	0,31	1,24%

Stopa zwrotu z portfela	0,408%
--------------------------------	--------

Źródło: Opracowanie własne.

Tabela 77. Portfel zbudowany w oparciu o model 3.

Model 3		
Spółka	Waga w portfelu poszczególnych spółek wg. metody Probit Portfolio	Stopa zwrotu skorygowana o wagę w portfelu
Ruch	0,54	-1,49%
Ponar	0,46	-3,47%

Stopa zwrotu z portfela	-4,963%
--------------------------------	----------------

Źródło: Opracowanie własne.

Tabela 78. Wyselekcjonowane portfele akcji wraz ze stopami zwrotu.

Kapit_PrzepOp	Stopa zwrotu	Cena1_WK1	Stopa zwrotu	PrzepNe	Stopa zwrotu
Comarch	7,89%	Comarch	7,89%	Nepentes	-7,30%
Ruch	-2,77%	Wielton	-13,33%	ElstarOil	12,93%
Erbud	-16,23%	Erbud	-16,23%	Comarch	7,89%
AzotyTarnów	0,46%	Hawe	-10,29%	Barlinek	1,38%
Hawe	-10,29%	Nepentes	-7,30%	AzotyTarnów	0,46%
	-4,19%		-7,85%		3,08%
	Inwestor zajmuje krótką pozycję		Inwestor zajmuje krótką pozycję		Inwestor zajmuje krótką pozycję
Wynik z inwestycji	4,19%	Wynik z inwestycji	7,85%	Wynik z inwestycji	-3,08%

Źródło: Opracowanie własne.

Ostateczne zestawienie przedstawia tabela 79, która zawiera syntetyczne porównanie metod omawianych w tymże rozdziale.

Tabela 79. Podsumowanie wyników według stopy zwrotu dla poszczególnych strategii

Średnia z 3 portfeli strategii momentum	2,99%
Średnia z 3 modeli probitowych	-1,40%
Średnia wynik z indeksu sWig80	-2,82%
Stopa zwrotu dla wszystkich spółek (próbki) w zbiorze testowym	-6,76%

Źródło: Opracowanie własne.

6.6. Analiza wyników.

Głównym celem pracy była odpowiedź na pytanie, czy model probitowy może być skutecznym narzędziem w procesie wyboru spółek do portfela na podstawie zmian wskaźników finansowych. Wyniki wskazują, że strategia oparta na wskazaniach modelu probitowego przyniosłaby stopę zwrotu wyższą niż strategia pasywna.

Zaprezentowane wyniki wskazują, że najbardziej efektywnym kryterium dobroci modelu jest kryterium łączne składające się ze średniego błędu absolutnego oraz z R-kwadrat McFaddena będące kryterium wyboru dla modelu 1. Jednak średnia stopa zwrotu z portfela dla tego modelu wyniosła 0,4% i była tylko nieznacznie wyższa (o 0,05%) od modelu 2, którego kryteriami dobroci był iloraz szans oraz ranking łączny. Warto zauważyć, iż cecha charakterystyczną miar: średniego błędu absolutnego oraz z R-kwadrat McFaddena jest ich skłonność do liniowego wzrostu wraz z usuwaniem kolejnych najmniej istotnych zmiennych.

Następnie autor starał się odpowiedzieć na pytanie, czy strategia inwestycyjna oparta o model probitowy jest w stanie uzyskać wyższą stopę zwrotu, niż strategia oparta o metodę momentum. Badanie wykazało, iż średnio model probitowy nie jest w stanie osiągnąć stopy zwrotu wyższej, niż strategia momentum, która w badanym okresie uzyskała stopę zwrotu równą 2,99%, przy ujemnej stopie zwrotu modeli probitowych wynoszącej -1,4%. Warto jednak zaznaczyć, iż obie metody inwestowania na rynku kapitałowym pokonały benchmark, jakim była średnia stopa zwrotu z indeksu sWig80, która wyniosła -2,82%. Wydaje się jednak, że odpowiednim benchmarkiem powinna być średnia stopa zwrotu dla 22 spółek, które weszły do zbioru testowego. Ta stopa zwrotu była jeszcze niższa i wyniosła -6,48%.

Bardzo ciekawe wnioski można wysunąć zagłębiając się w retorykę kolejnego pytania, na które autor chciał udzielić odpowiedzi. W toku badań autor doszedł do wniosku iż można

wybrać czynniki dotyczące kondycji finansowej przedsiębiorstwa, które determinują jego przyszły wzrost lub spadek wartości w stosunku do indeksu, w skład którego wchodzi. Na bazie obserwacji z trzech kwartałów, okazało się, iż te czynniki to:

- Zmiany wskaźnika *Kapitalizacja - Przepływy z działalności operacyjnej*
- Zmiany wskaźnika *Cena 1 akcji / Wartość księgową 1 akcji*
- Zmiany wskaźnika *Przepływy netto*

Zaprezentowane wyniki w tabeli 6 wskazują iż, w okresie treningowym spółki, które posiadały najwyższe zmiany wskaźnika *Kapitalizacja - Przepływy z działalności operacyjnej* zazwyczaj osiągały niższą stopę zwrotu niż indeks sWig80. Taki rezultat nie może dziwić zakładając, że zwiększa się kapitalizacja spółki przy spadających przepływach operacyjnych. Oznacza to, iż spółka jest droższa (więcej warta) natomiast środki generowane z podstawowej działalności firmy spadają. Taka sytuacja musi niepokoić inwestorów i skłonić ich do wyceny spółki poniżej wyceny rynku. Taki schemat działania inwestorów obowiązywał przez 3 okresy treningowe, również w okresie testowym strategia oparta na zajmowaniu krótkich pozycji na tych akcjach przyniosłaby zysk w wysokości 4%.

Kolejnym wskaźnikiem, który determinował zachowanie się spółek względem indeksu była zmiana wskaźnika *Cena 1 akcji / Wartość księgową 1 akcji*. Podobnie jak w przypadku poprzedniego wskaźnika, inwestorzy oceniali negatywnie duże zmiany tego wskaźnika. Okazało się bowiem, że tylko 1 z 10 spółek posiadając najwyższe wartości tego wskaźnika pokonała rynek małych spółek. Tak więc, bazując na danych z okresu treningowego należy stwierdzić, że duże zmiany wskaźnika *1 akcji / Wartość księgową 1 akcji* dla spółek giełdowych są interpretowane przez rynek jako oznaka słabszego zachowania się spółki w przyszłym kwartale względem swojego benchmarku. Poddając to interpretacji na gruncie analizy finansowej, można stwierdzić, iż spółka, która zwiększa swoją wycenę rynkową i równocześnie nie idzie za tym wzrost wartości bilansowej, posiada mniejszy potencjał wzrostu. Opisany schemat wnioskowania inwestorów sprawdził się również w okresie testowym. Zajmując pozycję krótką na 5 akcjach spółek, które posiadały najwyższy wyżej omawiany wskaźnik można było średnio zarobić 7,85%.

Wreszcie ciekawe wnioski można wyciągnąć analizując kolejną determinantę. Otóż z badań wynika, że spółki które posiadają najniższe wartości wskaźnika *Przepływy netto* zachowują się gorzej od rynku. W okresie treningowym ta reguła dotyczyła 9 z 10 spółek, które

posiadały najniższy poziom wyżej omawianego wskaźnika. Można sądzić, iż inwestorzy negatywnie oceniają spółki z niezdrowym cash flow, nadając istotną wagę zasadzie kasowej w analizie finansowej spółki. Ujemne przepływy gotówkowe wydają się być złym prognostykiem przyszłej wartości spółki. Analizując okres testowy, inwestor, który zająłby pozycję krótką na akcjach takich spółek byłby stratny średnio o -3,08%.

Zaprezentowane wyniki stanowią podstawę do dalszych badań, które powinny uwzględnić więcej okresów (kwartałów) zarówno w próbie treningowej, jak i testowej. Dodatkowo analizie można by poddać moment hipotetycznego zakupu i sprzedaży akcji. Mógłby być on jeden dla wszystkich spółek, np. momentem zakupu mógłby być dzień w którym ostatnia spółka poddana badaniu poda dane finansowe, natomiast momentem sprzedaży dzień poprzedzający publikację kolejnych wyników przez pierwszą ze spółek.

Podsumowanie.

Niniejsza praca dotyczy problematyki modelowania procesu alokacji aktywów za pomocą modeli dwumianowych. Zaprezentowano teoretyczne aspekty dotyczące procesu alokacji aktywów oraz ekonometrycznych modeli dwumianowych. W części empirycznej przedstawiono możliwości wykorzystania modelu probitowego w czterech różnych obszarach rynków finansowych.

Cześć pierwsza składa się z 2 rozdziałów opisujących zagadnienia teoretyczne związane z wykorzystaniem modeli dwumianowych w procesie alokacji aktywów.

W pierwszym rozdziale autor skupił swoją uwagę na podstawowych zagadnieniach, które prezentują znaczenie oraz fundamenty procesu alokacji aktywów. Poza tym opisano charakterystykę procesu alokacji aktywów, klasyfikując go ze względu na orientację, styl oraz kryterium wyboru metody tworzenia portfela aktywów. Dodatkowo przedstawiono metody, główne implikacje oraz literaturę dotyczącą dywersyfikacji międzynarodowej.

W drugim rozdziale zostały przedstawione podstawowe pojęcia z zakresu modelowania zmiennych jakościowych. Szczególną uwagę autor poświęcił metodom estymacji i weryfikacji statystycznej modeli dwumianowych opisując metodę największej wiarygodności oraz miary dopasowania modelu, jak i prognozy na podstawie modeli dwumianowych. Przedstawiono również możliwości i ich wykorzystania do analizy niektórych finansowych szeregów czasowych.

Zmienność rynków finansowych implikuje zasadniczo różne skutki dla różnych grup aktywów, modeli czy strategii. Prace nad poszczególnymi obszarami badawczymi przyniosły interesujące rezultaty.

Analizując wyniki dla obszaru pierwszego stwierdzono, że krótkoterminowe odchylenia w stopach zwrotu na spreadzie między indeksami dużych i małych spółek mogą być lepiej wyjaśniane przez modele probitowe w porównaniu ze strategią kup i sprzedaj oraz strategią momentum. Autor znalazł również odpowiedzi na pytania poboczne. Kryterium dobroci modelu, które najlepiej opisuje odchylenia na spreadzie Wig20 – sWig80 okazał się być iloraz szans. Dodatkowo okazało się, iż model, który był preferowany pod względem dwóch kryteriów

nie wyróżnił się pozytywnie na tle pozostałych. Dodatkowo okazało się, że dywersyfikacja w przypadku tak silnie skorelowanych instrumentów nie daje pozytywnych wyników. Okazało się bowiem, iż w celu maksymalizacji wskaźnika stopa zwrotu / odchylenie standardowe należy cały kapitał inwestować w Wig20 lub sWig80.

Analiza obszaru drugiego dowiodła pewnej prawidłowości zaczerpniętej z rozważań nad obszarem pierwszym. Otóż, potwierdziła się teza, iż skuteczniejszym kryterium dobroci modelu jest ponownie iloraz szans. Modele, które były wybierane na podstawie tego kryterium osiągnęły stopę zwrotu wyższą średnio o ponad 1 % niż modele wybierane na podstawie kryterium testu ilorazu wiarygodności.

Interesujące wnioski można również wysunąć przypatrując się zmiennym, które weszły w skład modeli efektywnych. Okazało się, że żadna ze zmiennych prognozujących odchylenie między indeksami Wig20 i sWig80, nie weszła w skład modeli prognozujących spread między SP 500, a DJIA. Wynikać to może z dwóch faktów. Po pierwsze modele te selekcjonowane były według różnych metod i po drugie, może to dowodzić, iż przyszłymi odchyleniami między polskimi indeksami a amerykańskimi rządzią różne przyczyny

W toku postępowania badawczego nad obszarem trzecim okazało się, że model probitowy jest skuteczniejszy niż strategia pasywna. Porównując uśrednione wyniki strategii probitowych oraz strategii momentum należy stwierdzić, iż skuteczniejsze są portfele inwestycyjne oparte na strategii momentum. Analiza kryteriów dobroci modeli probitowych wykazała, iż model który był efektywny pod względem zarówno ilorazu szans oraz rankingu łącznego najlepiej opisuje odchylenia na spreadzie Złoto – S&P 500, Złoto – Dolar/Jen oraz S&P 500 – Dolar/Jen..

W toku badań nad istotnością zmiennych w modelach probitowych okazało się, że dla poszczególnych spreadów można wyróżnić zmienne w poszczególnych modelach, które w istotny sposób prognozują jego kierunek. Dodatkowo okazało się, że dla tych zmiennych nie zawsze miejsce w rankingu Simsa pokrywa się z miejscem na liście najistotniejszych zmiennych w modelach probitowych. Tylko w przypadku zmiennej SP400_2 (zmiana wartości indeksu S&P400 opóźniona o 2 okresy) stwierdzono, iż powtórzyła swoje miejsce na liście najistotniejszych zmiennych w modelach z tym, które zajęła w rankingu Simsa. Wreszcie dowiedziono, iż w większości przypadków nie są stabilne relacje oparte na jednej zmiennej mającej średnio największy wpływ na dany spread według modeli efektywnych. Wykazano to za

pomocą różnicy w stopach zwrotu jaką otrzymano budując strategię opartą o daną zmienną w dwóch okresach; przed estymacją modeli i po estymacji. Jedynie zmienna Ryz_2 (zmiany cen ryżu opóźnione o 2 okresy) w modelu spreadu Złoto – Dolar / Jen okazała się być stabilna na tyle, że skumulowana stopa zwrotu okazała się być dodatnia, jednak o ponad 50% niższa niż w okresie treningowym.

Empiryczne odkrycia w obszarze czwartym wskazują, że model probitowy jest skutecznym narzędziem w procesie wyboru spółek do portfela na podstawie zmian wskaźników finansowych. Wyniki wskazują, że strategia oparta na wskazaniach modelu probitowego przyniosłaby stopę zwrotu wyższą niż strategia pasywna.

Nie do końca natomiast udało się odpowiedzieć na pytanie, które z kryteriów dobroci modelu okazało się najskuteczniejsze. Zaprezentowane wyniki wskazują, że najbardziej efektywnym kryterium dobroci modelu jest kryterium łączne składające się z średniego błędu absolutnego oraz R-kwadrat McFaddena. Jednak średnia stopa zwrotu z portfela dla tego modelu wyniosła 0,4% i była tylko nieznacznie wyższa (o 0,05%) od modelu, którego kryteriami dobroci modelu był iloraz szans oraz ranking łączny. Warto zauważyć, iż cechą charakterystyczną miar: średniego błędu absolutnego oraz z R-kwadrat McFaddena jest ich skłonność do liniowego wzrostu wraz z usuwaniem kolejnych najmniej istotnych zmiennych.

Następnie autor starał się odpowiedzieć na pytanie: czy strategia inwestycyjna oparta o model probitowy jest w stanie uzyskać wyższą stopę zwrotu niż strategia oparta o metodę momentum. Badanie wykazało, iż średnio model probitowy nie jest w stanie osiągnąć stopy zwrotu wyższej, niż strategia momentum która w badanym okresie uzyskała stopę zwrotu równą 0,2% przy ujemnej stopie zwrotu modeli probitowych wynoszącej -1,4%. Warto jednak zaznaczyć, iż obie metody inwestycyjne pokonały benchmark jakim była średnia stopa zwrotu z indeksu sWig80 która wyniosła -2,82%. Wydaje się jednak, że odpowiednim benchmarkiem powinna być średnia stopa zwrotu 22 spółek, które weszły do zbioru testowego. Ta stopa zwrotu wyniosła -6,48%.

Interesujące wnioski można wysunąć zagłębiając się w retorykę kolejnego pytania. W toku badań autor doszedł do wniosku iż, można wybrać czynniki dotyczące kondycji finansowej przedsiębiorstwa, które determinują jego przyszły wzrost lub spadek wartości w stosunku do

indeksu w skład którego wchodzi. Na bazie obserwacji z 3 kwartałów, okazało się, iż te czynniki to:

- Zmiany wskaźnika *Kapitalizacja - Przepływy z działalności operacyjnej*
- Zmiany wskaźnika *Cena 1 akcji / Wartość księgową 1 akcji*
- Zmiany Przepływów netto

Analiza danych ze wszystkich czterech obszarów badawczych wskazuje, iż modele probitowe okazały się skutecznym narzędziem w procesie alokacji aktywów. Prawie we wszystkich obszarach empirycznych średni wynik z modeli probitowych charakteryzował się wyższą stopą zwrotu lub, w przypadku gdy stopa zwrotu była dodatnia, wskaźnikiem stopa zwrotu / odchylenie standardowe w relacji do strategii pasywnych. Jedynie w obszarze trzecim, w strategii głównej, średnia stopa zwrotu z modeli probitowych okazała się być niższa, jednak wynik ten należy ostrożnie interpretować, gdyż w tym przypadku ustalenie definicji strategii pasywnej nie jest jednoznaczne.

Trzeba zwrócić uwagę na szerokie możliwości używanych modeli. Jednym z ograniczeń jest dostępność instrumentów. Na giełdzie polskiej nadal nie ma możliwości zajęcia pozycji na kontrakcie na sWig80, tym samym nie ma możliwości w praktyce kontrolować zbiór spółek wchodzących w skład tego indeksu. Dodatkowo kompletnej implementacji wszystkich strategii w obszarze czwartym utrudnia fakt, iż na WGPW nadal nie ma oficjalnej możliwości zajmowania krótkich pozycji na wszystkich akcjach.

Spis tabel

Tabela 1. Typy procesu alokacji aktywów	15
Tabela 2. Główne klasy aktywów	17
Tabela 3. Systematyka modeli zmiennych jakościowych i ograniczonych	19
Tabela 4. Tablica „trafności” modelu dwumianowego.....	24
Tabela 5. Wyniki testu Sims’a dla zmiennych niezależnych.....	35
Tabela 6. Wyniki testu Sims’a dla zmiennych typu spread	36
Tabela 7. Ranking testu Sims’a według wartości p w ujęciu procentowym	38
Tabela 8. Poszczególne modele probitowe	42
Tabela 9. Poszczególne modele probitowe, z których usunięto najmniej istotną zmienną	43
Tabela 10. Model otrzymany algorytmem regresji krokowej wstecznej	43
Tabela 11. Zmienne istotne w danych modelach dla zbioru treningowego i testowego	46
Tabela 12. Wyniki portfela opartego na strategii 1.....	47
Tabela 13. Wyniki portfela opartego na strategii 2.....	47
Tabela 14. Wyniki portfela opartego na strategii 1.....	50
Tabela 15. Wyniki portfela opartego na strategii 2.....	51
Tabela 16. Wyniki według przyjętych kryteriów dobroci modelu	53
Tabela 17. Podsumowanie ilościowe indeksów SP 500 i DJIA za okres 1/1995 – 6/2009 w ujęciu miesięcznym	58
Tabela 18. Strategia 1	64
Tabela 19. Strategia 2	65
Tabela 20. Strategia pasywna	65
Tabela 21. Średnie wyniki według danej strategii	65
Tabela 22. Średnie wyniki według kryterium dobroci wyboru modelu	65
Tabela 23. Średnie wyniki według kryterium wymiaru modelu.....	66
Tabela 24. Ranking testu Simsa dla spreadu Złoto – S&P500 według wartości p w ujęciu procentowym.....	77
Tabela 25. Ranking testu Simsa dla spreadu Złoto – Dolar / Jen według wartości p w ujęciu procentowym	78

Tabela 26. Ranking testu Simsa dla spreadu S&P500 - Dolar / Jen według wartości p w ujęciu procentowym.....	79
Tabela 27. Poszczególne modele probitowe i ich charakterystyki dla spreadu Złoto – S&P500.....	80
Tabela 28. Poszczególne modele probitowe, z których usunięto najmniej istotną zmienną dla spreadu Złoto – S&P500.....	81
Tabela 29. Modeli probitowe na podstawie metody regresji krokowej wstecznej dla spreadu Złoto – S&P500	82
Tabela 30. Modele probitowe wg. poszczególnych kryteriów dobroci modelu dla spreadu Złoto – S&P500.....	83
Tabela 31. Ranking łączny modeli probitowych dla spreadu Złoto – S&P500.....	85
Tabela 32. Poszczególne modele probitowe i ich charakterystyki dla spreadu Złoto – Dolar / Jen.....	92
Tabela 33. Poszczególne modele probitowe, z których usunięto najmniej istotną zmienną dla spreadu Złoto - Dolar / Jen.....	93
Tabela 34. Modeli probitowe na podstawie metody regresji krokowej wstecznej dla spreadu Złoto – S&P500	94
Tabela 35. Modele probitowe wg. poszczególnych kryteriów dobroci modelu dla spreadu Złoto – Dolar / Jen.....	95
Tabela 36. Ranking łączny modeli probitowych dla spreadu Złoto – S&P500.....	97
Tabela 37. Poszczególne modele probitowe i ich charakterystyki dla spreadu S&P500 – Dolar / Jen.....	102
Tabela 38. Poszczególne modele probitowe z których usunięto najmniej istotną zmienną dla spreadu S&P500 - Dolar / Jen.....	103
Tabela 39. Modeli probitowe na podstawie metody regresji krokowej wstecznej dla spreadu S&P500 - Dolar / Jen	104
Tabela 40. Modele probitowe wg. poszczególnych kryteriów dobroci modelu dla spreadu Złoto – Dolar / Jen.....	105
Tabela 41. Ranking łączny modeli probitowych dla spreadu S&P500 – Dolar/Jen.....	106
Tabela 42. Wyniki portfela opartego na strategii 1 dla spreadu Złoto – S&P500	

oraz benchmark.....	112
Tabela 43. Wyniki portfela opartego na strategii 2 dla spreadu Złoto – S&P500.....	112
Tabela 44. Wyniki portfela opartego na strategii 3 dla spreadu Złoto – S&P500.....	113
Tabela 45. Średnia dla danego modelu z zaprezentowanych strategii dla spreadu Złoto – S&P500.....	113
Tabela 46. Wyniki portfela opartego na strategii 1 dla spreadu Złoto – Dolar / Jen oraz benchmark.....	113
Tabela 47. Wyniki portfela opartego na strategii 2 dla spreadu Złoto – Dolar / Jen.....	114
Tabela 48. Wyniki portfela opartego na strategii 3 dla spreadu Złoto – Dolar / Jen.....	114
Tabela 49. Średnia dla danego modelu z zaprezentowanych strategii dla spreadu Złoto – Dolar / Jen.....	114
Tabela 50. Wyniki portfela opartego na strategii 1 dla spreadu S&P500 – Dolar / Jen oraz benchmark.....	115
Tabela 51. Wyniki portfela opartego na strategii 2 dla spreadu S&P500 – Dolar / Jen.....	115
Tabela 52. Wyniki portfela opartego na strategii 3 dla spreadu S&P500 – Dolar / Jen.....	116
Tabela 53. Średnia dla danego modelu z zaprezentowanych strategii spreadu S&P500 – Dolar / Jen.....	116
Tabela 54. Wyniki portfela opartego na strategii 1, 2 oraz 3 oraz benchmark.....	118
Tabela 55. Uśrednione wyniki portfela.....	118
Tabela 56. Wyniki startegii głównej z perspektywy inwestora amerykańskiego i polskiego.....	123
Tabela 57. Wyniki według przyjętych kryteriów dobroci modelu.....	124
Tabela 58. Wartości współczynnika p dla poszczególnych modeli oraz wartość średnia.....	124
Tabela 59. Ranking Simsa dla wybranych zmiennych.....	124
Tabela 60. Charakterystyki ilościowe dla portfela skonstruowanego na podstawie zmiennej ObIUs30_Złoto_2.....	125
Tabela 61. Wartości współczynnika p dla poszczególnych modeli oraz wartość średnia.....	
Tabela 62. Ranking Simsa dla wybranych zmiennych.....	126
Tabela 62a. Charakterystyki ilościowe dla portfela skonstruowanego na podstawie zmiennej Ryz_2.....	126
Tabela 63. Wartości współczynnika p dla poszczególnych modeli.....	

oraz wartość średnia.....	127
Tabela 64. Ranking Simsa dla wybranych zmiennych	128
Tabela 65. Charakterystyki ilościowe dla skonstruowanego na podstawie zmiennej SP400_2	128
Tabela 67. Wybrane spółki z indeksu sWig80.....	137
Tabela 68. Wykaz zmiennych użytych do badania.....	140
Tabela 69. Prezentacja parametrów modeli za pomocą algorytmu regresji krokowej	143
Tabela 70. Modele probitowe wg. poszczególnych kryteria dobroci modelu	145
Tabela 71. Ranking łączny dla najlepszych siedmiu modeli probitowych.....	145
Tabela 72. Wybrane zmienne do analizy na zbiorze testowym wraz z ich sytuacjami Momentum.....	149
Tabela 73. Wybrane spółki i wartości zmiennych objaśniających	150
Tabela 74. Lista spółek wraz z prognozami.....	150
Tabela 75. Portfel zbudowany w oparciu o model 1	152
Tabela 76. Portfel zbudowany w oparciu o model 2	152
Tabela 77. Portfel zbudowany w oparciu o model 3	153
Tabela 78. Wyselekcjonowane portfele akcji wraz ze stopami zwrotu	153
Tabela 79. Podsumowanie wyników według stopy zwrotu dla poszczególnych strategii	154

Spis wykresów

Wykres 1. Stopy zwrotu skumulowane w ujęciu procentowym.....	31
Wykres 2. Spread skumulowany w ujęciu procentowym: sWig80 – Wig20	31
Wykres 3. Skumulowana stopa zwrotu. Podejście 1. Strategia 1	49
Wykres 4. Skumulowana stopa zwrotu. Podejście 1. Strategia 2	
Wykres 5. Spread w ujęciu procentowym między modelem ważonym, a strategią kup i trzymaj. Podejście 1. Strategia 1	49
Wykres 6. Spread w ujęciu procentowym między modelem ważonym, a strategią kup i trzymaj. Podejście 1. Strategia 2	50
Wykres 7. Skumulowana stopa zwrotu. Podejście 2. Strategia 1	51
Wykres 8. Skumulowana stopa zwrotu. Podejście 2. Strategia 2	52

Wykres 9. Spread w ujęciu procentowym między modelem ważonym, a strategią kup i trzymaj. Podejście 2. Strategia 1	52
Wykres 10. Spread w ujęciu procentowym między modelem ważonym, a strategią kup i trzymaj. Podejście 2. Strategia 2	53
Wykres 11. Skumulowany spread między SP 500 i DJIA w ujęciu procentowym	59
Wykres 12. Różnica w ujęciu procentowym między najlepszymi modelami ze strategii 1 oraz 2.....	66
Wykres 13. Przedstawia skumulowane stopy zwrotu w ujęciu procentowym dla Złota.....	70
Wykres 14. Spread w ujęciu procentowym między Złotem a indeksem S&P 500	71
Wykres 15. Spread w ujęciu procentowym między Złotem a Dolar / Jen.....	71
Wykres 16. Skumulowane stopy zwrotu w ujęciu procentowym dla indeksu S&P 500.....	72
Wykres 17. Skumulowane stopy zwrotu w ujęciu procentowym dla waluty Dolar / Jen	73
Wykres 18. Spread między indeksem S&P 500 a Dolar / Jen.....	73
Wykres 19. Zestawienie skumulowanych stóp zwrotu dla strategii 1, 2 oraz 3	119
Wykres 20. Skumulowane stopy zwrotu dla strategii momentum	119
Wykres 21. Skumulowane stopy zwrotu dla strategii 2 oraz strategii pasywnej	120
Wykres 22. Różnica w skumulowanych stopach zwrotu dla strategii 2 oraz strategii pasywnej	121
Wykres 23. Skumulowane stopy zwrotu dla strategii momentum 1 oraz 2 oraz strategii 3.....	121
Wykres 24. Skumulowane stopy zwrotu dla strategii momentum 3 oraz strategii 1.....	122
Wykres 25. Skumulowana stopa zwrotu dla strategii uwzględniającej tylko zmienną ObIUs30_Zloto_2	125
Wykres 26. Skumulowana stopa zwrotu dla strategii uwzględniającej tylko zmienną Ryz_2	127
Wykres 27. Skumulowana stopa zwrotu dla strategii uwzględniającej tylko zmienną SP400_2	129

Spis obrazów

Obraz 1. Moduł wyboru zmiennych objaśniających oraz wymiaru modelu	62
Obraz 2. Moduł estymacji modeli.....	63

Spis diagramów

Diagram 1. Przykładowy przebieg procesu zakupu i sprzedaży akcji.....143

Bibliografia:

Abtowa J., Piasecki K., Różański T., Świtalski Z. [2007] *Matematyka wspomagająca zarządzanie*, Wydawnictwo: Akademii Ekonomicznej w Poznaniu

Anderson H.M. [1997] *Transaction Costs and Nonlinear Adjustment Towards Equilibrium in The US Treasury Bill Markets*, Oxford Bulletin of Economics and Statistics, Vol.59

Arendarski P. [2009] *Wykorzystanie modelu probitowego do prognozowania wzrostu wartości rynkowej polskich przedsiębiorstw z branży spożywczej notowanych na WGPW*, IV Konferencja Młodych Uczonych w Krakowie

Arendarski P. [2010] *Wykorzystanie procentowych kontraktów futures do spekulacji na krzywej dochodowości*, Zeszyty Studiów Doktoranckich UEP, Poznań

Arshanapalli B. G., Coggin T. D., Doukas, J. [1998] *Multifactor Asset Pricing Analysis of International Value Investment Strategies*, Journal of Portfolio Management

Arshanapalli B. G., Switzer L., Hung L. [2004] *Active versus Passive Strategies for EAFE and S&P 500*, Journal of Portfolio Management

Ball R., Brown P. [1968] *An Empirical Evaluation of Accounting Income Numbers*, Journal of Accounting Research, 6, pp. 159-178

Bauman W., Conover C., Miller R. [1998] *Growth Versus Value And Large Versus Small Cap Stocks In International Markets*” Financial Analysts Journal

Baur D., Lucey B. [2009] *Is Gold a Hedge or a Safe Haven? An Analysis of Stocks, Bonds and Gold*, Dublin City University – Business School, Dublin

Batóg B., Wawrzyniak K. [2005] *Modele probitowe i logitowy jako podstawa systemu diagnoz na przykładzie sektorów warszawskiej giełdy papierów wartościowych*, Zeszyty Naukowe Uniwersytetu Szczecińskiego

- Batóg B., Wawrzyniak K. [2004] *Diagnozowanie i prognozowanie kondycji spółek giełdowych za pomocą modeli probitowych i logitowych*. Rynek Kapitałowy. Skuteczne inwestowanie. Część I. Wydawnictwo Naukowe Uniwersytetu Szczecińskiego, Szczecin
- Batóg B., Wawrzyniak K. [2007] *Efektywność prognoz pozytywnej diagnozy łącznej sytuacji ekonomiczno-finansowej spółek giełdowych*. Rynek Kapitałowy. Skuteczne inwestowanie. Część I. Zeszyty Naukowe Uniwersytetu Szczecińskiego nr 462
- Bernard A., Thomas V., Wahlen J. [1998] *Accounting-based stock price anomalies: Separating market inefficiencies from risk*, Contemporary Accounting Research 14, s. 89-136
- Burzała M.M. [2009] *Próba oszacowania prawdopodobieństwa realizacji europejskiej opcji kupna na przykładzie indeksu Wig20*, Studia i prace wydziału Nauk Ekonomicznych i Zarządzania
- Breen W., Golsten L. R., Jagannathan R. [1989] *Economic significance of predictable variations in stock index returns*, Journal of Finance, 44[5], 1177-1189
- Campbell J., Lo A, MacKinlay C. [1997] *The Econometrics of Financial Markets*, Princeton University Press
- Capual C., Rowley I., Sharpe W. [1993] *International Value and Growth Stock Returns*, Financial Analysts Journal
- Cutler D., Poterba J., Summers L. [1989] *What Moves Stock Prices?* NBER Working Paper Series, Vol. w2538
- Czekaj J., Woś W., Tarnowski J. [2001] *Efektywność giełdowego rynku akcji w Polsce*, Wydawnictwo PWN, Warszawa, s. 112
- Damodaran A. [1996] *Investment Valuation*, John Wiley & Sons Inc.
- Darst D.,A. [2008] *Art of asset allocation*, McGorw & Hill, Nowy Jork
- Elleuch J., Trabelsi L. [2009] *Fundamental Analysis Strategy and the Prediction of Stock Returns*, International Research Journal of Finance and Economics
- Fama E, Fisher L., Jensen M., Roll R. [1969] *The Adjustment of Stock Prices to New Information*, International Economic Review, 10, pp. 1-21

- Fama E., French K. [1998] *Value versus Growth: The International Evidence*, Journal of Finance, American Finance Association, vol. 53[6]
- Fan D., Lau K-N., Leung P-L. [1998] *Combining ordinal forecasts with an application in a financial market*, Journal of Forecasting, vol. 15
- Foster, Olsen, Shevlin [1984] *Earnings releases, anomalies, and the behavior of security returns*, Accounting Review
- Gokani B., Todorovic N. [2006] *Profitability of Quantitative vs. Momentum Size and Style Rotation Strategies in the UK Equity Market*
- Gruszczyński M. [2009] *Ekonometria i badania operacyjne*, Wydawnictwo Naukowe PWN, s. 179-181
- Gruszczyński M. [2002] *Modele i prognozy zmiennych jakościowych w finansach i bankowości*, „Monografie i Opracowania”, nr 490, Szkoła Główna Handlowa, Warszawa
- Hardy D. [1990] *Market Timing and International Diversification*, Journal of Portfolio Management, 16, s. 23-27
- Holthausen R.W., Larcker D.F. [1992] *The prediction of stock returns using financial statement information*, Journal of Accounting and Economics 15, s. 373-412
- Hudson D. [2008] *Up, up and away with TAA*, Money Management, Reed Business Information Australia - Vol. 03.04.2008
- Jeffrey R. [1984] *The Folly of Stock Market Timing*, Harvard Business Review
- Jegadeesh N., Titman S. [1993] *Returns to Buying Winners and Selling Losers: Implications for Stock Market Efficiency*, “Journal of Finance”, Vol. 48, No. 1, s. 65–89
- Kairys J. P. [1993] *Predicting sign changes in the equity risk premium using commercial paper rates*, The Journal of Portfolio Management 20 [1], s. 41-51
- Kao D. Schumaker R.D. [1999] *Equity Style Timing*, Financial Analysts Journal
- Klemkosky R., Bharati R. [1995] *Time-Varying Expected Returns and Asset. Allocation*, The Journal of Portfolio Management

Lo A., MacKinlay C. [1990] *Data-Snooping Biases in Tests of Financial Asset Pricing Models*, Review of Financial Studies, Oxford University Press for Society for Financial Studies, vol. 3[3], pages 431-67

Lee W. [2000] *Theory and Methodology of Tactical Asset Allocation*, Frank J. Fabozzi,

Maddala G.S. [2006] *Ekonometria*, PWN, Warszawa

Morton R., Shane P. [1998] *The information environment and ability o logit-based financial statement analysis to predict abnormal returns*, Accounting and Finance 38, s. 71-89

Nam J. S., Branch B. [1994] *Tactical asset allocation: Can it work ?* Journal of Financial Research, 17[4], 465-479

Osińska M. [2008] *Ekonometryczna analiza zależności przyczynowych*, Wydawnictwo Naukowe Uniwersytetu Mikołaja Kopernika, Toruń, s. 79-81

Ou J.A., Penman H.S. [1989] *Financial statement analysis and the prediction of stock returns*, Journal of Accounting and Economics 11, s. 295-329

Pesaran H., Timmermann A. [1995] *Predictability of Stock Returns: Robustness and Economic Significance*, University of California at San Diego, Economics Working Paper Series 95-19, Department of Economics, UC San Diego

Reinganum, M. R. [1999] *The Significance of Market Capitalisation in Portfolio Management Over Time*, Journal of Portfolio Management

Sharpe W., Alexander G. [1990] *Investments*, Wydanie 4, Englewood: Prentice Hall

Liu W., Resnick B., Shoesmith G. [2004] *Market Timing of International Stock Markets using the Yield Spread*, The Journal of Financial Research, Vol. XXVII, No. 3 , Pages 373–391, Fall 2004

Schweser C. [2008] *Podręcznik dla kandydatów na CFA, numer 2: Zarządzanie portfelowe dla instytucyjnych inwestorów, koncepcje ekonomiczne i proces alokacji aktywów*, Schweser Institut, Nowy Jork

http://akson.sgh.waw.pl/~mtomczyk/Slajdy_06.pdf