

dr hab. Agnieszka Majewska, prof. US
Katedra Finansów Zrównoważonych i Rynków Kapitałowych
Instytut Ekonomii i Finansów
Wydział Ekonomii, Finansów i Zarządzania
Uniwersytet Szczeciński

**Recenzja pracy doktorskiej Grzegorza Tratkowskiego
pt. „Dynamiczna optymalizacja portfela inwestycyjnego z wykorzystaniem
uczenia ze wzmocnieniem”**

1. Uwagi ogólne, znaczenie problematyki

Pojęcie optymalizacji portfela inwestycyjnego od dziesięcioleci jest przedmiotem badań naukowych. W tym roku mija 70 lat opublikowania przez Harry’ego Markowitza w *Journal of Finance* artykułu pt. *Portfolio Selection*, w którym ustanowiono zupełnie nową koncepcję optymalizacji portfela. Zaproponowane przez niego holistyczne podejście uwzględniające występowanie w portfelu wielu aktywów było ważnym elementem w teorii inwestowania, która fundamentalnie zmieniła sposób, w jaki inwestorzy indywidualni i instytucjonalni podchodzą do budowy portfela papierów wartościowych. Od tego czasu powszechne stało się uwzględnianie w procesie decyzyjnym związku między ryzykiem a stopą zwrotu. Zdecydowana większość badań odnoszących się do optymalizacji portfela inwestycyjnego opiera się na wykorzystaniu metod matematycznych i statystycznych. Wraz z rozwojem nowych technologii, w tym w szczególności sztucznej inteligencji (AI) oraz automatyzacji i robotyki (RPA), otworzyła się możliwość przetwarzania ogromnych zbiorów różnorodnych danych. Sztuczna inteligencja przez uwzględnienie większych i bardziej złożonych zbiorów danych oraz często całkowite zautomatyzowanie procesu decyzyjnego, przyspieszyła i usprawniła proces podejmowania decyzji.

Przekazana mi do recenzji rozprawa wpisuje się w aktualne trendy wykorzystania sztucznej inteligencji w branży finansowej. Rosnące wydatki firm na rozwiązania z zakresu sztucznej inteligencji świadczą o dużym zapotrzebowaniu na sprawdzone algorytmy uczenia maszynowego. Autor podjął się zbadania możliwości wykorzystania uczenia ze wzmocnieniem w optymalizacji portfela inwestycyjnego. Ten rodzaj uczenia maszynowego w porównaniu do dwóch pozostałych (tj. uczenia nadzorowanego oraz nienadzorowanego) jest znacznie rzadziej

uwzględniany w badanych obejmujących tematykę konstrukcji portfeli inwestycyjnych. Dlatego też badania w tym zakresie są jak najbardziej zasadne. Z tego powodu wybór tematu rozprawy doktorskiej podjęty przez magistra Grzegorza Tratkowskiego uważam za uzasadniony. Podjęte zagadnienie jest aktualne oraz istotne z teoriopoznawczego oraz przede wszystkim z praktycznego punktu widzenia.

2. Cel, hipotezy i metody badawcze

Autor sformułował dwa główne cele pracy. Jako **pierwszy główny cel** wskazał „przeprowadzenie przeglądu literatury dotyczącego zastosowania uczenia maszynowego w procesie zarządzania portfelem inwestycyjnym”. Z kolei **drugi główny cel** pracy to „weryfikacja skuteczności budowy dynamicznego (wielookresowego z uwzględnieniem kosztów transakcyjnych) portfela inwestycyjnego z zastosowaniem algorytmu uczenia ze wzmocnieniem w porównaniu z klasycznym podejściem Markowitza”. Moja ogólna uwaga w tym zakresie odnosi się do faktu, że przegląd literatury nie powinien stanowić celu głównego, gdyż jest to metoda badawcza. Wystarczające byłoby pozostanie tylko przy drugim celu głównym, do którego Autor odniósł cztery cele szczegółowe:

- „weryfikację efektywności wybranego algorytmu na różnych klasach aktywów (akcje, obligacje, waluty, towary);
- weryfikację wpływu awersji do ryzyka inwestora na efektywność portfela dla poszczególnych klas aktywów;
- weryfikację skuteczności poszczególnych metod budowy portfela inwestycyjnego w zależności od stanu rynku (wzrosty, spadki).
- polemikę z wynikami uzyskiwanymi na zbyt małej liczbie instrumentów lub krótkim okresie, które prowadzą do zbyt optymistycznych interpretacji w zakresie wykorzystania danych narzędzi”.

Sformułowane trzy pierwsze cele szczegółowe określają co będzie przedmiotem badań empirycznych, zatem odnoszą się wyłącznie do rozdziału 4 dysertacji. Czwarty cel w moim przekonaniu został niewłaściwie sformułowany i jest tutaj zbędny. Szkoda, że Autor nie sformułował celów szczegółowych w zakresie trzech pierwszych rozdziałów pracy.

We wstępie oprócz celów podana została teza. Zamiast tezy Autor powinien użyć hipotezy, bowiem teza jest założeniem, które się udowadnia a hipoteza podlega weryfikacji, tak jak ma to miejsce w pracy. Na etapie projektowania badania nie wiemy jeszcze czy „wykorzystanie metod uczenia ze wzmocnieniem i uwzględnianie wieloetapowego podejmowania decyzji prowadzi do lepszych efektów finansowych mierzonych różnymi

kryteriami w porównaniu do podejścia klasycznego”. Jest to nasze przypuszczenie, które wymaga dopiero zweryfikowania (potwierdzenia lub falsyfikacji).

Pomimo pewnych nieścisłości i braków ogólnie oceniam, że przedstawione cele pozwalają na poznanie głównych zamierzeń badawczych Autora i sformułowanie oczekiwań odnośnie zawartości pracy. Biorąc pod uwagę intencje Autora, można uznać, że cel główny został zrealizowany.

W pracy oprócz standardowych metod badawczych tj. analizy piśmiennictwa w zakresie podjętej tematyki, zastosowano metody uczenia ze wzmocnieniem.

3. Układ i konstrukcja rozprawy oraz jej ogólna ocena merytoryczna

Praca liczy łącznie 302 strony. Składa się z wprowadzenia, czterech rozdziałów, zakończenia, bibliografii, spisu tabel i rysunków oraz dodatku, który zwiera wykaz szeregów czasowych wykorzystanych w badaniu empirycznym. Przyjęta struktura pracy jest właściwa i zgodna z ogólnie przyjętymi standardami. Dysertacja opiera się na 384 pozycjach literatury, która w większości obejmuje pozycje anglojęzyczne. Dobór literatury, zarówno pod względem ilościowym, jak i jakościowym oceniam pozytywnie.

Wstęp ma charakter ogólny i zawiera wszystkie podstawowe elementy wymagane w tego typu opracowaniach tj. przedstawienie problemu, cel pracy, hipotezę badawczą, nakreślenie przedmiotu badań, opis zawartości poszczególnych rozdziałów.

Trzy pierwsze rozdziały mają charakter teoretyczny: jeden odnosi się do zarządzania portfelem inwestycyjnym, dwa kolejne do uczenia maszynowego i algorytmów uczenia ze wzmocnieniem. W moim przekonaniu w rozdziale drugim i trzecim brakuje odniesień pokazujących, jak przedstawione teorie dotyczące uczenia maszynowego są adoptowane do zarządzania portfelem inwestycyjnym. Rozdział czwarty obejmuje empiryczne badanie wybranych algorytmów w budowie portfela inwestycyjnego. Poniżej przedstawiona zostanie szczegółowa ocena poszczególnych rozdziałów

Rozdział pierwszy (*Zarządzanie portfelem inwestycyjnym*) przedstawia główne zagadnienia odnoszące się do portfela inwestycyjnego. Rozważania Autor rozpoczął od przedstawienia pasywnego i aktywnego zarządzania portfelem w kontekście efektywności informacyjnej rynków finansowych. Kolejne części tego rozdziału poświęcone są charakterystyce inwestora i polityce inwestycyjnej, strategiom inwestycyjnym, budowie portfela inwestycyjnego oraz ocenie efektywności. W moim przekonaniu kolejność poszczególnych podrozdziałów mogła być nieco inna. Autor powinien rozpocząć swoje rozważania od pojęcia inwestora, następnie przejść do budowy i zarządzania portfelem inwestycyjnym, a zakończyć na miarach efektywności. Odnoszę wrażenie, że Doktorant chcąc

uwzględnić jak najwięcej zagadnień dotyczących portfela inwestycyjnego nie ustrzegł się chaosu i braku ciągłości rozważań. Część elementów mogła być pominięta bez szkody dla pracy, np. pkt 1.3. *Strategie inwestycyjne*, przedstawiający ogólny opis strategii inwestowania w akcje na podstawie analizy fundamentalnej i technicznej. Poniżej przedstawię moje szczegółowe uwagi dotyczące niektórych elementów tej części dysertacji. Zaprezentowana tabela 1 (s. 17) podsumowująca wyżej wymienione rodzaje zarządzania, zawiera w moim przekonaniu niewłaściwe tłumaczenia pracy źródłowej Pedersena [2015], tj. „efektywnie nieefektywny rynek”. Niektórych zwrotów nie można wprost tłumaczyć na język polski. Autor w tej części podaje również błąd śledzenia (s. 20) jako podstawową miarę oceniającą pasywne zarządzanie (dowołuje się również do niej w dalszych częściach pracy i wzorach), jednak brak jest wyjaśnienia i opisu tej miary. Niezrozumiały jest dla mnie rysunek 4 (s. 56) przedstawiający przykładowy schemat zmiany wartości portfela inwestycyjnego z uwzględnieniem zewnętrznych przepływów pieniężnych (w obecnej postaci nie wnosi o żadnej treści). W tabeli 3 (s. 57) dla zmodyfikowanej wewnętrznej stopy zwrotu Autor używa oznaczenia w_t , które definiuje jako wagę korygującą stosowaną do zewnętrznych przepływów pieniężnych w dniu t . W matematyce finansowej powszechnie stosuje się oznaczenie t , które po prostu oznacza kolejne okresy inwestycji. Równania (30) i (31) str. 58 przedstawiające stopę zwrotu dla przepływów pieniężnych dokonywanych na końcu oraz początku okresu mają ten sam wynik końcowy. W części poświęconej miarom stopy zwrotu portfela Autor w dużej mierze oparł się na pracy Bacona [2008], stąd zapewne wynikają różnice w oznaczeniach i zapisach. Szkoda, że Doktorant dodatkowo nie odniósł się do obszernej w tym zakresie literatury polskiej. Tą część dysertacji podsumowuję jako umiarkowanie pozytywną. Pomimo wskazanych uwag, odniesiono się do najważniejszych elementów budowy portfela inwestycyjnego.

Rozdział drugi (*Uczenie maszynowe w zarządzaniu portfelem inwestycyjnym*) przedstawia teorię z zakresu uczenia maszynowego jako obszaru sztucznej inteligencji. Po przedstawieniu trzech rodzajów uczenia maszynowego, omówione zostały dla nich miary efektywności. Na podstawie literatury przedmiotu Doktorant przedstawia poszczególne algorytmy i miary, niestety bez dodatkowo komentarza odnośnie możliwości wykorzystania przy ocenie efektywności portfela inwestycyjnego. W wielu miejscach przy prezentowanych formułach nie wskazano źródła i pojawiają się braki w opisie symboli występujących w równaniach. Rysunek 6 (s. 86) przedstawiający elementy uczenia ze wzmocnieniem jest dla mnie mało czytelny. Autor mógł uzupełnić poszczególne elementy o terminologię używaną w ekonomii i finansach (np. co będzie oznaczało środowisko, akcja, nagroda, stan itd. w kontekście wykorzystania uczenia ze wzmocnieniem w optymalizacji portfela inwestycyjnego). Podobnie rysunek 8 (s. 92) jest dla mnie niezrozumiały i nie potrafię dopatrzeć się tam

elementów występujących przy jego opisie. Z kolei rysunek 7 (s. 91), dla którego brak jest opisu nie wnosi nic do pracy. Interesujące są tabele zestawiające wybrane miary efektywności. Pozytywnie oceniam podsumowanie wybranych miar oceniających klasyfikację binarną (tabela 9, s. 106) oraz miar oceny rozwiązania problemów regresji (tabela 10, s. 113). Praca zyskałaby na wartości, gdyby Autor dla każdego rodzaju uczenia maszynowego dokonał zestawienia wykorzystywanych algorytmów i podsumowania dla nich miar efektywności. W ostatnim podrozdziale Autor chcąc nawiązać do wykorzystania uczenia maszynowego w budowie portfela inwestycyjnego dokonał systematyzacji literatury, co niewłaściwie nazwał przeglądem literatury. Nie odwoływał się bowiem do treści poszczególnych pozycji literatury, lecz przeprowadził porządkowanie według różnych kryteriów. Pomimo błędnie użytej nazwy Autor dokonał wartościowej systematyzacji i wskazał obszary największej aktywności badaczy oraz podał luki badawcze. Wskazana luka badawcza potwierdziła zasadność prowadzenia przez Autora badań w tym zakresie.

W trzecim rozdziale dysertacji Autor szczegółowo odnosi się do algorytmów uczenia ze wzmocnieniem. Na podstawie Zhang i Yu [2020] przedstawił podział tych algorytmów (rysunek 16, s. 149). Część sformułowań, które zostały podane przy klasyfikacji budzi moje wątpliwości. Pierwsza odnosi się to tłumaczenia *model-free*. Uważam, że tłumaczenie „wolne od modeli” nie oddaje istoty tych algorytmów. Według mnie lepsze byłoby użycie określenia algorytm bezmodelowy lub pozostawienie nazwy angielskiej. Druga moja uwaga dotyczy sformułowania „bandyta”. Co ono oznacza w kontekście przedstawionej klasyfikacji? Szczegółowo Doktorant odniósł się kilku algorytmów. W schemacie nie doszukałam się opisywanego później algorytmu REINFORCE. Ta część pracy byłaby czytelniejsza, gdyby opis dokonany był z podziałem na dwie wyróżnione wcześniej grupy tj. algorytmy oparte na modelach (pkt. 3.1.5) oraz algorytmy bezmodelowe (pkt. 3.1.1-3.1.4). Z uwagi na dużą ilość i złożoność algorytmów *model-free* szkoda, że Autor oddzielnie nie przedstawił dla nich klasyfikacji. Ważnym elementem tej części pracy jest dokonane przez Doktoranta podsumowanie zawierające zalety i wady algorytmów uczenia ze wzmocnieniem (tabela 24, s. 170). Świadczy to o dobrej znajomości badanego tematu i umiejętności wyciągania wniosków. Można było jedynie wskazać przy algorytmach, do której z dwóch wyróżnionych grup należą. Wartościowy jest przegląd literatury obejmujący zastosowania uczenia ze wzmocnieniem w budowie portfela inwestycyjnego. Autor dokładnie przeanalizował dwadzieścia pozycji pod względem dziewięciu kryteriów i na tej podstawie wyłonił algorytm (G-learning), który został wykorzystany później w empirycznej części pracy. Wykazał się tutaj umiejętnością krytycznego myślenia. W dalszej części rozdziału przedstawił teorię odnoszącą się do samego algorytmu G-learning oraz problemu budowy portfela z wykorzystaniem tego algorytmu. W celu możliwości wykorzystania algorytmu G-learning do optymalizacji portfela

inwestycyjnego, opierając się na pracy Dixona i Halperina [2020] oraz Dixona, Halperina i Bilokona [2020] zaadoptował zaproponowane przez nich rozwiązanie problemu zarządzania majątkiem. Zabrakło mi uzasadnienia, dlaczego w badaniu empirycznym założono, że stopa benchmarku wynosić będzie 10% (s. 195) oraz wskazania w podrozdziale 3.4 źródła prezentowanych formuł i równań.

Czwarty rozdział pracy przedstawia wyniki badania efektywności algorytmu G-learning w budowie optymalnego portfela inwestycyjnego. Jako wskaźnik oceny efektywności Autor przyjął stosunek stopy zwrotu skorygowanej o koszty transakcyjne do ryzyka mierzonego odchyleniem standardowym. Jest to poprawne podejście często wykorzystywane w badaniu efektywności. Uzyskane wyniki zostały zestawione z rezultatami otrzymanymi dla klasycznego modelu Markowitza oraz jego dynamicznego rozszerzenia uwzględniającego koszty transakcyjne. Uwzględnienie w badaniu kosztów transakcyjnych jest dużą zaletą, jednak Autor nie wskazał co wchodziło w ich skład, czy była to *a priori* przyjęta wartość. W opisie metodyki badania zabrakło mi uzasadnienia, dlaczego Doktorant wybrał spółki z indeksu S&P 500 oraz STOXX Europe 600. Podobnie nie podano jakie były przesłanki wyboru obligacji dla 13 państw europejskich, strefy euro oraz sześciu państw spoza Europy. Należy podkreślić, że Doktorant nie ograniczył swoich badań do jednego rodzaju aktywów. Łącznie dla czterech klas aktywów (akcje, obligacje, towary, waluty) zgromadził 400 szeregów czasowych. Mam wątpliwości co do przyjętego uproszczenia, dla którego oczekiwane stopy zwrotu przedstawione zostały jako średnie stopy zwrotu z ostatnich 260 obserwacji. W przypadku dziennych stóp zwrotu wyznaczając średnią stopę zwrotu dla tak długiego okresu otrzymuje się wartości oscylujące wokół zera. Niepoprawne jest podawanie współczynników korelacji w procentach, bowiem są one wielkościami niemianowanymi. W opisie danych generowanych Autor podał zakresy trzech parametrów uwzględnionych w algorytmie G-learnig (tabela 27, s. 218). Nie podał jednak, jakie były podstawy przyjęcia takich zakresów. Podobnie nie uzasadnił, dlaczego przyjął określone wartości tych parametrów (awersji do ryzyka - 7 wariantów, kosztów transakcyjnych - 1 wariant, współczynnik dyskontowy - 1 wariant. Badania efektywności wykorzystania uczenia ze wzmocnieniem w optymalizacji portfela inwestycyjnego zostało przeprowadzone dla poszczególnych czterech klas aktywów oraz dla portfela mieszanego. Tabele przedstawiające wyniki badań empirycznych niepotrzebnie uwzględniają informacje, które zostały ujęte w kolejnych tabelach odnoszących się do pomiaru efektywności portfeli inwestycyjnych. Zweryfikowano hipotezę badawczą o tym, że portfele zbudowane za pomocą algorytmu G-learnig w porównaniu z klasycznym podejściem osiągają lepsze wyniki dla każdej klasy aktywów osobno oraz wszystkich łącznie, zatem cele pracy zostały zrealizowane. Otwarte pozostaje pytanie czy osiągnięte wyniki istotnie były wyższe w porównaniu z klasycznym

podejściem. Należy docenić przeanalizowanie obszernej bazy danych. Jak podaje Autor wygenerował łącznie 14,4 mln portfeli, co wymagało 15 dni obliczeń na 7 komputerach.

Reasumując, pomimo wskazanych powyżej niedoskonałości, recenzowaną rozprawę oceniam pozytywnie. Magister Grzegorz Tratkowski wykazał, że potrafi sformułować i rozwiązać problem naukowy. Wykazał się znajomością problematyki, w szczególności odnoszącej się do uczenia maszynowego.

4. Najważniejsze osiągnięcia pracy

Podstawowym osiągnięciem pracy jest przedstawienie możliwości wykorzystania algorytmu uczenia ze wzmocnieniem G-learning do optymalizacji portfela inwestycyjnego. Na podstawie przeglądu literatury przedmiotu stwierdził, że brak jest ustalonej i kontrolowanej metodyki testowania efektywności strategii i portfeli inwestycyjnych. Ważne jest również spostrzeżenie, że obecnie publikacje z tego zakresu prowadzą do zbyt optymistycznych założeń w zakresie wykorzystania algorytmów uczenia maszynowego w finansach.

Lektura pracy pozwoliła mi na sformułowanie następujących pytań, na które Doktorant będzie mieć okazję odpowiedzieć podczas publicznej obrony:

1. Weryfikacja efektywności algorytmu ze wzmocnieniem G-learning wskazała uzyskiwanie przeciętnie lepszych wyników. Jakie znaczenie dla uzyskanych wyników mają z góry przyjęte wartości trzech kryteriów tj. awersji do ryzyka, koszty transakcyjne oraz współczynnik dyskontowy?
2. Rosnące wydatki firm na rozwiązania z zakresu sztucznej inteligencji wskazują na duże zainteresowanie tą dziedziną. Według raportu Precedence Research globalna wielkość rynku uczenia maszynowego jako usługi szacowana była w 2021 roku na 15,47 mld USD, natomiast oczekuje się, że do 2030 r. osiągnie około 305,62 mld USD. Jak ocenia Pan możliwości wykorzystania uczenia maszynowego przez inwestorów:
 - indywidualnych
 - instytucjonalnych?
3. Z uwagi na to, że uczenie maszynowe jest stosunkowo nowo dziedziną, dla której brak jest jeszcze wypracowanych standardów, jak ocenia Pan bezpieczeństwo korzystania z narzędzi uczenia maszynowego. Jakie rodzaje ryzyka mogą ulec zwiększeniu w związku z powszechniejszym użyciem tych narzędzi na rynku finansowym?

5. Uwagi szczegółowe

W kilku miejscach występują pewne nieścisłości i niefortunne zwroty, niemające jednak fundamentalnego znaczenia dla całościowej oceny pracy. Poniżej zamieszczam ich przykłady:

- s. 14 – „słaba wersja hipotezy”
- s. 48 – „polega na redukcji wariancji próbkowanej zmiennej zaniedbywalnie zwiększając obciążenie estymacji”
- s. 52 – „pozycji o zaniedbywalnych wagach”
- s. 85 – „postawionym od osiągnięcia celom”
- s. 96 – błędne określenie: „Celem może być statystyczne wnioskowanie, które służy znalezieniu relacji lub nawet przyczynowości między zmiennymi”
- s. 101 – „współczynnik fi” (o jaki współczynnik w rzeczywistości chodziło?)
- s. 104 – „kiepski model”
- s.107 – „wartość prawdziwa” (powinno być empiryczna)
- s. 124 – „trzy miary dotyczące takiego wykresu”
- s. 125 – „z określonymi założeniami dotyczącymi samej rozgrywki”
- s. 165 – „W przypadku eksploracji strategii relatywnie łatwo jest uszkodzić maszynę...”
- s. 199 – „wybrano 50 największych podmiotów” – zapewne chodziło o 50 spółek z najwyższą kapitalizacją
- w kilku miejscach używanie określenia zwrot zamiast stopa zwrotu.

6. Formalna strona rozprawy

Praca została dobrze przygotowana pod względem formalnym. Doktorant poznał i właściwie stosuje terminologię z badanej tematyki. Dostrzeżone błędy językowe, literowe oraz gramatyczne nie utrudniają śledzenia logiki wyводу i dlatego nie prezentują niedociągnięć w tym zakresie.

7. Konkluzja

Rozprawę doktorską magistra Grzegorza Tratkowskiego oceniam pozytywnie – zalety pracy zdecydowanie przewyższają jej niedostatki. Część wskazanych przeze mnie uwag miała zresztą charakter polemiczny.

Autor wykazał, że potrafi samodzielnie sformułować problem naukowy oraz przedstawić rozwiązanie tego problemu, zatem posiada umiejętność samodzielnego prowadzenia pracy naukowej. Przedłożona mi do oceny rozprawa doktorska potwierdza znajomość przez Kandydata wiedzy teoretycznej i literatury przedmiotu z obszaru stanowiącego przedmiot badań. Pozwoliło to Jemu na zrealizowanie celów rozprawy.

Dlatego też uważam, że **praca doktorska magistra Grzegorza Tratkowskiego pt. „Dynamiczna optymalizacja portfela inwestycyjnego z wykorzystaniem uczenia ze wzmocnieniem”** magistra Grzegorza Tratkowskiego **spełnia wymogi stawiane pracom doktorskim** zgodnie z art. 187 ustawy z dnia 20 lipca 2018 r. Prawo o szkolnictwie wyższym i nauce (Dz. U. z 2018 r. poz. 1668 ze zm.). Wnioskuje zatem o dopuszczenie tej rozprawy do publicznej obrony.

Szczecin, 12.12.2022

A handwritten signature in blue ink, appearing to read 'd. Tratkowski', is positioned to the right of the date.

