

Poznań, 22.11.2022

dr hab. Agata Kliber, prof. UEP
Katedra Matematyki Stosowanej
Uniwersytet Ekonomiczny w Poznaniu
Al. Niepodległości 10
61-875 Poznań

Recenzja rozprawy doktorskiej

pana magistra Grzegorza Tratkowskiego p.t. *Dynamiczna optymalizacja portfela inwestycyjnego z wykorzystaniem uczenia ze wzmocnieniem*
napisanej na Wydziale Ekonomii i Finansów Uniwersytetu Ekonomicznego we Wrocławiu, pod kierunkiem dr. hab. prof. UEW Krzysztofa Piontka

Rozprawa doktorska pana magistra Grzegorza Tratkowskiego pt. *Dynamiczna optymalizacja portfela inwestycyjnego z wykorzystaniem uczenia ze wzmocnieniem* poświęcona jest zagadnieniu doboru instrumentów do portfela inwestycyjnego z wykorzystaniem algorytmów uczenia maszynowego. Wykorzystanie uczenia maszynowego w finansach jest coraz bardziej popularne zarówno wśród teoretyków, jak i inwestorów. Tematyka pracy jest zatem aktualna a wnioski z przeprowadzonego badania mogą mieć zastosowanie w praktyce.

Teza, cel pracy i pytania badawcze

Tezą pracy pana magistra Grzegorza Tratkowskiego jest (str. 9 rozprawy): *wykorzystanie metod uczenia ze wzmocnieniem i uwzględnianie wieloetapowego podejmowania decyzji prowadzi do lepszych efektów finansowych mierzonych różnymi kryteriami w porównaniu do podejścia klasycznego.*

Autor określił następujące cele główne rozprawy:

1. Przeprowadzenie przeglądu literatury dotyczącego zastosowania uczenia maszynowego w procesie zarządzania portfelem inwestycyjnym.
2. Weryfikacja skuteczności budowy dynamicznego (wielookresowego z uwzględnieniem kosztów transakcyjnych) portfela inwestycyjnego z zastosowaniem algorytmu uczenia ze wzmocnieniem w porównaniu z klasycznym podejściem Markowitza.

Pan magister Tratkowski zdefiniował również cele szczegółowe, związane z drugim celem pracy. Są to:

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

Struktura pracy

Rozważania zostały zaprezentowane na 264 stronach: we Wstępie, czterech rozdziałach i Zakończeniu. Spis literatury obejmuje 384 pozycje, zarówno książkowe, jak i najnowsze artykuły z badanego zakresu.

Rozprawę rozpoczyna **Wstęp**, szczegółowo informujący czytelnika o tle i znaczeniu badań, celach, hipotezach i układzie pracy. **Rozdział pierwszy: Zarządzanie portfelem inwestycyjnym** zawiera szeroki przegląd metod stosowanych w zarządzaniu portfelem. Autor rozpoczyna go od przedstawienia koncepcji efektywności informacyjnej rynku i związanych z nią metod zarządzania portfelem. Następnie koncentruje się na możliwych strategiach inwestowania w zależności od cech inwestora, w szczególności jego awersji do ryzyka. Przedstawia spotykane w literaturze podejścia do budowy portfela inwestycji, odwołując się do teorii użyteczności, teorii portfelowej oraz zagadnienia optymalizacji portfela. Ostatecznie, opisuje funkcjonujące w literaturze podejścia do oceny efektywności inwestycji.

Rozdział ten jest dobrze napisany. Autor powołuje się w nim zarówno na klasyczne pozycje literaturowe, jak również na najnowsze publikacje. Stanowi on dobre wprowadzenie do dalszych części pracy, a zwłaszcza do **rozdziału drugiego: Uczenie maszynowe w zarządzaniu portfelem inwestycyjnym**. Rozdział ten koresponduje z **pierwszym celem pracy** i zawiera przegląd literatury dotyczącej uczenia maszynowego oraz możliwego zastosowania tych technik w procesie zarządzania portfelem inwestycyjnym. Autor dokonuje przeglądu metod uczenia maszynowego: bez nadzoru, z nadzorem i ze wzmacnianiem, szczególny nacisk kładąc

na te ostatnie. Rozdział napisany jest dokładnie i wyczerpująco. Na podkreślenie zasługują liczne tabele, które syntetycznie podsumowują wady i zalety stosowanych podejść. Na szczególną uwagę zasługuje też tabela podsumowująca przegląd literatury dotyczący zastosowania uczenia maszynowego do zarządzania portfelem inwestycyjnym. Usunęłabym jedynie opis kwerendy – czytelnika interesuje raczej jej wynik, a nie dokładny opis sposobu wyszukiwania prac naukowych.

W rozdziale trzecim *Algorytmy uczenia ze wzmacnianiem* Autor przedstawia syntetyczny przegląd algorytmów uczenia ze wzmacnianiem, kładąc szczególny nacisk na ten, który ostatecznie został zastosowany w badaniu empirycznym (rozdział czwarty). Na podkreślenie zasługuje przedstawienie kilku klasyfikacji tego typu algorytmów, w zależności od wybranych kryteriów. W tym rozdziale Autor przedstawia kolejny przegląd literatury dotyczący wykorzystania algorytmów uczenia ze wzmacnianiem do budowy portfela inwestycyjnego. Na podstawie tego przeglądu uzasadnia wybór swojej ostatecznej procedury badawczej.

Rozdział czwarty zatytułowany *Badanie efektywności wybranych algorytmów w budowie optymalnego portfela inwestycyjnego* jest rozdziałem **empirycznym**. Autor przedstawia w nim wprowadzoną przez siebie modyfikację testu Lopeza de Prado (2016), a następnie wykorzystuje swoją autorską wersję testu do oceny efektywności portfeli inwestycyjnych zbudowanych z wykorzystaniem algorytmu G-Learning.

Problemem, który pojawia się przy ocenie efektywności strategii inwestycyjnej jest możliwość pojawienia się efektu przeuczenia algorytmu, który w efekcie, mimo iż dobrze sprawdza się „w próbie”, nie osiąga założonej skuteczności poza nią. Efekt ten nosi w literaturze nazwę *backtest overfitting* i jest konsekwencją zjawiska zwanego problemem porównań wielokrotnych. Zjawisko to występuje przy wielokrotnym testowaniu tej samej rodziny hipotez jednocześnie i polega na zwiększeniu prawdopodobieństwa popełnienia błędu pierwszego rodzaju ponad założony poziom istotności, a tym samym wzroście ryzyka omyłkowego przyjęcia hipotezy alternatywnej, która jest w rzeczywistości prawdziwa (Miller, 1981). Jednym ze sposobów rozwiązania tego problemu jest wykorzystanie metod symulacyjnych i bootstrapowych. W cytowanej pracy (Lopez de Prado, 2016), autor testuje swój algorytm na podstawie sztucznie wygenerowanych trajektorii gaussowskiego białego szumu o określonej długości, które następnie modyfikuje je tak, aby były zbliżone do danych empirycznych, tj. wprowadza do danych losowe szoki oraz korelacje. Trajektorie generowane są 10 000 razy, a okres treningowy i testowy są z góry ustalone. Modyfikacja pana magistra Tratkowskiego polegała na wprowadzeniu losowości okresu testowego (początek próby testowej ustalany jest w sposób losowy) oraz zastąpieniu symulacji losowaniem szeregów z

jednej z czterech grup: akcji, obligacji, kursów walutowych i towarów. Podejście to można porównać z rodzajem losowania bootstrapowego z prób, którymi są odpowiednio: zbiór szeregów akcji, obligacji, kursów walutowych i towarów.

Kolejnym rozszerzeniem badania Lopeza de Prado (2016) zaproponowanym przez pana magistra Tratkowskiego jest porównanie efektywności tworzonych przez algorytm portfeli inwestycyjnych z określonymi benchmarkami, tj. klasycznym modelem Markowitza, modelem Markowitza uwzględniającym koszty transakcyjne oraz portfelem z równymi wagami w całym okresie inwestycji. Celem badania była ocena efektywności portfeli konstruowanych przez algorytm G-learning przy zmianie parametrów: awersji do ryzyka, kosztów transakcyjnych i współczynnika dyskontowego.

Wyniki badania są obiecujące. Autor pokazuje między innymi, że portfele budowane z użyciem algorytmu G-Learning uzyskiwały przeciętnie lepsze wyniki dla każdej rozważanej klasy aktywów osobno i wszystkich łącznie. Przewaga algorytmu nad innymi metodami jest szczególnie widoczna, gdy rynek znajduje się w trendzie spadkowym.

Należy podkreślić, że badanie przedstawione w tym rozdziale zostało bardzo dokładnie opisane i objaśnione krok po kroku. Struktura tego rozdziału wskazuje na to, że Autor zaprojektował proces badawczy w sposób przemyślany. Na końcu rozdziału Autor zamieścił syntetyczne i klarowne podsumowanie wyników, uzyskanych wniosków oraz możliwości (czy też konieczności) dalszych badań.

Rozprawę zamyka **Zakończenie**, w którym Autor jeszcze raz podsumowuje badania przeprowadzone w poszczególnych rozdziałach, cele pracy i główne wnioski, jakie sformułował w kolejnych etapach badania oraz wskazuje kierunki dalszych badań.

Najważniejsze osiągnięcia Autora

Najważniejszymi osiągnięciami Autora przedstawionymi w recenzowanej rozprawie są:

1. Rozszerzenie testu Lopeza de Prado (2016) stosowanego do weryfikacji efektywności portfela inwestycyjnego poprzez uwzględnienie w nim różnych klas aktywów oraz losowości wyboru próby uczącej.
2. Zaprojektowanie i przeprowadzenie badania empirycznego obejmującego 14.4 miliony unikalnych portfeli inwestycyjnych.
3. Opracowanie i usystematyzowanie literatury dotyczącej aspektów zarządzania portfelem inwestycyjnym oraz uczenia ze wzmocnieniem.

Na szczególne podkreślenie zasługuje czytelna i logiczna struktura pracy oraz wywodów Autora, rzetelne i staranne przygotowanie przeglądu literaturowego obejmującego teorię portfelową i aspekty uczenia maszynowego, a także imponujące badanie empiryczne. W związku z powyższym czytelnik nie ma wątpliwości, że oba jasno zdefiniowane cele rozprawy zostały osiągnięte.

Dyskusyjne aspekty pracy i pytania do Autora

Moją pierwszą wątpliwość budzi sformułowanie tezy pracy:

Wykorzystanie metod uczenia ze wzmocnieniem i uwzględnianie wieloetapowego podejmowania decyzji prowadzi do lepszych efektów finansowych mierzonych różnymi kryteriami w porównaniu do podejścia klasycznego.

Użycie w tym kontekście sformułowania: *różne kryteria* wydaje mi się zbyt enigmatyczne. Autor ostatecznie stosuje trzy kryteria (stopa zwrotu, odchylenie standardowe i wskaźnik stopy zwrotu do ryzyka) i uważam, że powinny być one wyraźnie wymienione w tezie pracy.

Druga wątpliwość odnosi się do stwierdzenia ze strony 9: „Autor zdecydował się zrezygnować z weryfikacji statystycznej istotności ze względu na duże obciążenie wyborem danych testowych oraz teorię fałszywej strategii, co jest powodem braku możliwości osiągnięcia uogólnionych wniosków dotyczących skuteczności danego narzędzia w finansach (Lopez de Prado i Bailey, 2021)”. Przede wszystkim – nie jest zrozumiałe, czego istotność miałby Autor testować? Ponadto pojęcia, którymi się posługuje: „obciążenie danych testowych” oraz „teoria fałszywej strategii” nie są tu wyjaśnione. Autor nawiązuje wprawdzie do powyższych pojęć na stronie 198, w podrozdziale opisującym metodykę badania, ale poświęca teorii fałszywej strategii zaledwie dwa zdania, między innymi stwierdzając, że „optymalny wynik nieznaney liczby symulacji historycznych modelu dopasowującego parametry portfela lub strategii jest prawostronnie nieograniczony”. W związku z tym nasuwa się pytanie, co to jest optymalny wynik symulacji i co jest symulowane – model, czy parametry? Co czytelnik ma rozumieć przez parametry portfela lub parametry strategii? W kolejnym zdaniu Autor pisze, że „przy wystarczającej liczbie prób nie istnieje np. wskaźnik Sharpe’a wystarczający do odrzucenia hipotezy, że dana strategia jest fałszywa.” Jest to dość ogólnikowe

stwierdzenie, w którym nie wyjaśnia się, co czytelnik ma rozumieć pod pojęciem „wystarczającej liczby prób”, ani czy teoria fałszywej strategii koncentruje się jedynie na wskaźniku Sharpe’a, czy również na innych miarach efektywności inwestycji. Podsumowując – bez przeczytania pracy Lopeza de Prado i Bailey’a (2021) czy też Bailey’a i in. (2017), trudno jest zrozumieć wywody Autora. Uważam, że problem został potraktowany zbyt pobieżnie, zwłaszcza że, jak rozumiem, spostrzeżenia Lopeza de Prado i Bailey’a, stoją u podstaw badania empirycznego przeprowadzonego przez Autora. Dobrze byłoby przynajmniej zarysować tło problemu, odwołując się najpierw do klasycznego problemu wielokrotnych porównań, a dopiero potem przedstawić, w jaki sposób ten problem pojawia się przy testowaniu strategii i skąd biorą się fałszywe strategie. Przed przejściem do przedstawienia rozwiązania Lopeza de Prado (2016) można byłoby wspomnieć, w jaki inny sposób różni autorzy mierzyli się z tym problemem. Sam Lopez de Prado proponuje w swoich artykułach kilka rozwiązań, np. *probabilistic Sharpe ratio* (Bailey i Lopez de Prado, 2012), *deflated Sharpe ratio* (Bailey i Lopez de Prado, 2014), wyznaczenie prawdopodobieństwa wystąpienia zjawiska nadmiernego dopasowania (Bailey i in., 2017) i wiele innych. Praca, do której odwołuje się Autor, tj. Lopez de Prado (2016) akurat nie koncentruje się na poszukiwaniu rozwiązania problemu nadmiernego dopasowania, ale jest propozycją rozwiązania problemu (braku) odwracalności macierzy w zadaniu Markowitza. Test, o którym pisze Doktorant, jest sprawdzeniem efektywności proponowanej w tym artykule metody i jego konstrukcja wynika z wcześniejszych prac autorów. Proszę Autora o rozwinięcie tego zagadnienia w trakcie obrony, a także wyjaśnienie, w jaki konkretnie sposób zastosowane przez niego podejście rozwiązuje problem zjawiska *backtest overfitting*.

W **rozdziale trzecim** moje wątpliwości budzi definicja używanych symboli. Przykładowo, symbolem π Autor oznacza czasami prawdopodobieństwo, a czasami strategię. Nie jest to dla mnie jasne – czy strategia utożsamiana jest z prawdopodobieństwem? Podobne wątpliwości budzi używane przez Autora pojęcie *bootstrappingu*. Jeśli nie jest to pojęcie tożsame z pojęciem bootstrapu stosowanym w statystyce, to powinno zostać wytłumaczone na początku rozdziału, zwłaszcza, że Autor pisze również równolegle o metodach symulacyjnych.

Kolejne pytania dotyczą sposobu modyfikacji algorytmu zaproponowanego w pozycji (Lopez de Prado, 2016). Modyfikacja ta sprowadza się do losowania różnych szeregów czasowych z czterech grup: akcji, obligacji, kursów walutowych oraz towarów. Takie rozwiązanie przypomina losowanie bootstrapowe z próby, podczas gdy w oryginalnym podejściu (Lopez de Prado, 2016) generowana jest pewna liczba procesów o ustalonych własnościach, a symulacja powtarzana jest 10 000 razy. Można tu zauważyć, że procesy

generowane w oryginalnym artykule, jak i w pierwszym kroku badania empirycznego przedstawionego w rozprawie doktorskiej, nie odzwierciedlają typowych cech finansowych szeregów czasowych, a w szczególności grupowania zmienności – dlatego za słuszne uważam podejście Autora, polegające na przetestowaniu algorytmu na danych rzeczywistych.

Wątpliwości czytelnika może jednak budzić samo wyodrębnienie grup. Na stronie 199 Autor pisze: „Wybór poszczególnych szeregów stop zwrotu miał na celu odzwierciedlać charakterystyki danej klasy aktywów”. Dobrze byłoby uzasadnić za pomocą testów statystycznych, że grupy te są istotnie zróżnicowane między sobą (i mało zróżnicowane wewnątrz podgrup). Autor przedstawia co prawda histogramy ilustrujące przeciętne stopy zwrotu w każdej klasie aktywów (Rysunki 21-24) oraz histogramy korelacji wewnątrzgrupowych (Rysunek 25) – jednak na przykład na podstawie histogramu korelacji między kursami walut (Rysunek 25) możemy zauważyć, że korelacje zawierają się w przedziale od -1 do 1, co w zasadzie kwestionuje zasadność stwierdzenia, że jest to grupa jednorodna.

Wydaje mi się, że zasadne byłoby przeprowadzenie testów statystycznych badających przynajmniej różnice w wartościach oczekiwanych i wariancjach zwrotów (które to wielkości Autor przedstawia w Tabeli 26), albo podzielenie szeregów ze względu na jednakowe własności statystyczne (średnia i odchylenie standardowe) oraz wysoki stopień korelacji wewnątrzgrupowej i losowanie szeregów z tak wyodrębnionych klas. Innym podejściem mogłoby być wygenerowanie procesów typu ARMA-GARCH o różnych własnościach i zweryfikowanie jakości działania algorytmu ze względu na różne własności procesu generującego dane.

W proponowanej modyfikacji pan magister Tratkowski losowo wybiera początek próby, która każdorazowo liczy 520 obserwacji. Ponieważ zbiór danych obejmuje lata 2006-2019 (choć na stronie 9 i 213 Autor pisze o zachowaniu szeregów w 2020 roku – czy okres badania ostatecznie został wydłużony?), nasuwa się pytanie o możliwe zmiany strukturalne szeregów i odporność algorytmu na te zmiany.

W badaniu empirycznym Autor (słusznie) zastosował zwroty proste (wzór 166). Czy według Autora miałyby sens zastosowanie w tym podejściu zwrotów logarytmicznych, stosowanych w modelowaniu szeregów czasowych? Zwroty logarytmiczne mają lepsze własności niż zwroty proste – między innymi przyjmują wartości z całej osi rzeczywistej, co ma znaczenie przy modelowaniu ich za pomocą rozkładów prawdopodobieństwa z nieograniczonym nośnikiem.

W większości przypadków okazało się, że portfele tworzone przez algorytm G-Learning uzyskują wyższe wyniki, gdy roczna stopa zwrotu rynku jest ujemna, a gorzej sprawdzają się

w sytuacji wzrostów na rynku. Czy Autor mógłby pokusić się o interpretację tego wyniku? Czy to oznacza, że algorytm ten mógłby mieć zastosowanie w okresach kryzysowych, a w okresach spokoju korzystniej byłoby wybrać inną metodą doboru instrumentów do portfela?

Opis metody, choć bardzo dokładny, nie jest do końca precyzyjny. Na stronie 205 Autor pisze, że generuje proces „o średniej równej zero oraz losowej macierzy kowariancji”. Co oznacza w tym przypadku losowość? Czy Autor zakłada, że macierz kowariancji jest zmienną losową i w każdym przypadku losuje wartość z jej rozkładu? Jeżeli tak, to jaki to rozkład? Następnie pojawia się stwierdzenie, że „szeregi zostały ustandaryzowane tak, że każdy z nich posiada odchylenie standardowe równe 1%”. Do czego odnoszą się procenty? Czy odchylenie stanowi 1% wartości oczekiwanej?

Ostatecznie, w badaniu empirycznym Autor mierzy między innymi korelację między średnimi miesięcznymi wskaźnikami zwrotu do ryzyka, które to wskaźniki przedstawia na wykresach. Czy Autor zbadał stacjonarność tych procesów? Jeśli nie są stacjonarne, to nie ma sensu liczenia korelacji między nimi.

Mankamenty rozprawy

Najslabszą stroną rozprawy jest niewątpliwie jej język. W pracy pojawiają się liczne błędy interpunkcyjne znacząco utrudniające odbiór przekazywanych treści. W rozprawie pojawiają się też błędy językowe oraz mniej liczne – ortograficzne. Szczególnie rażącym błędem ortograficznym jest niepoprawne użycie końcówki „ą” w celowniku liczby mnogiej, zamiast końcówki „om” (na przykład: na stronie 16 jest: „(...) odpowiadają poszczególnym efektywnością rynku” zamiast: „(...) odpowiadają poszczególnym efektywnościom rynku”; na stronie 18: „(...) odpowiadają proporcją (...)” zamiast: „(...) odpowiadają proporcjom (...))”).

Z błędów językowych szczególnie rzuca się w oczy użycie pojęcia „liczebnik” zamiast „licznik” (strona 66), stosowanie anglicyzmów, np. „pozytywne/negatywne” w znaczeniu: „dodatnie/ujemne”, „bazować na” w znaczeniu „opierać się na”, „sentyment” w znaczeniu „wydźwięk”, „charakterystyka” zamiast „cecha”, „wolny od modeli” zamiast „niezależny od modeli” i in.

Ostatecznie, w pracy pojawiają się czterdzieści dwie tabele oraz czterdzieści jeden wykresów. Uważam, że praca zyskałaby na czytelności, gdyby każda tabela i wykres miały swój własny opis, niezależnie od opisu w tekście. Same wykresy i tabele zostały przygotowane bardzo starannie i estetycznie.

Uwagi szczegółowe

Poniżej wymieniam mniej istotne uwagi i pytania, które wymagałyby doprecyzowania:

- Na stronie 67 brakuje rozwinięcia skrótu SML.
- Czy sieci neuronowe i drzewa decyzyjne można nazwać funkcjami (strona 78)?
- We wzorze (54) sumowanie powinno odbywać się po zmiennej s , a nie t , a indeks dolny przy R powinien wynosić $(t + s + 1)$.
- Przy opisie wielkości TP, TN, FN, FP, TPR i TNR (str. 97-98) proponowałabym posłużyć się prawdopodobieństwami warunkowymi, a nie częstościami.
- Przy opisie kofenetycznego współczynnika korelacji Autor posługuje się pojęciem odległości kofenetycznej, która nigdzie nie została zdefiniowana.
- We wzorze 113 brakuje wyjaśnienia, czym są n_{ij} i n .
- Pojęcie *mutual information* przetłumaczyłabym jako wspólna informacja, a nie wzajemna informacja. Przy opisie można byłoby dodać, że można ją znormalizować tak, aby przyjmowała wartości od 0 do 1 (tzw. globalny współczynnik korelacji – Menzes i in., 2004)
- Strona 114: nachylenie asymptoty. Czym jest ta asymptota?
- Strona 153⁶ – wydaje mi się, że pojęcie *bootstrapu* nie zostało tu użyte poprawnie – opis wskazuje bardziej na łańcuch Markowa.
- Strona 203: „Bollerslev [1986] uogólnił wcześniejszy model ARCH [Engle, 1982] do postaci GARCH, który modeluje warunkową heteroskedastyczność autoregresywnie (...)”. Ideą modelu ARCH jest modelowanie autoregresyjnej warunkowej heteroskedastyczności, a modyfikacja wprowadzona w modelu GARCH polegała na uogólnieniu tego podejścia.
- Str. 204: „(...) inną jego zaletą jest połączenie leptokurtycznego rozkładu zwrotów z grubymi ogonami modelowanymi przez skoki” – rozkład leptokurtyczny to właśnie rozkład z grubymi ogonami, a jedną z przyczyn wysokiej kurtozy są właśnie skoki. Wydaje mi się, że intencja Autora była inna.
- Str. 204: „(...) ponieważ testy empiryczne zazwyczaj faworyzują modele z wieloma parametrami”. Czy Autorowi chodzi o kryteria informacyjne? Jeśli tak, to jest ich wiele i w zależności od tego, czy interesuje nas oszczędnie sparametryzowanego modelu do prognoz, czy też modelu jak najlepiej opisującego historyczną dynamikę

szeregu, możemy się kierować wskazaniem tego, które posiada określone własności. Przykładem kryterium faworyzującego modele oszczędnie sparametryzowane jest kryterium bayesowskie (BIC).

- Str. 263 – czym jest „efekt szuflady publikowanych badań”?
- W spisie literatury pozycja Lopez de Prado (2018) pojawia się przed Lopez de Prado (2016).

Konkluzja

Przedstawione w recenzji wątpliwości nie wpływają znacząco na moją ogólną ocenę rozprawy doktorskiej pana magistra Grzegorza Tratkowskiego. Temat podjęty przez Doktoranta jest aktualny i wpisuje się w główny nurt badań w zakresie finansów empirycznych. Przedstawione w rozprawie badanie oparte jest na solidnej analizie literaturowej oraz imponującym badaniu empirycznym. Doktorant wykazał się rozległą wiedzą teoretyczną z zakresu analizy portfelowej oraz uczenia maszynowego. Poprawnie zidentyfikował lukę badawczą, postawił tezę i sformułował pytania badawcze. Zaproponowana przez niego metoda optymalizacji portfela inwestycyjnego z wykorzystaniem algorytmu uczenia ze wzmocnieniem (oraz rozbudowanie testu efektywności portfela) jest oryginalnym rozwiązaniem dobrze określonego problemu badawczego, co potwierdza zdolność pana magistra Tratkowskiego do prowadzenia samodzielnych badań naukowych.

Podsumowując przedstawione oceny i uwagi, stwierdzam, że recenzowana rozprawa doktorska spełnia warunki określone w Ustawie z dn. 20 lipca 2018r., *Prawo o szkolnictwie wyższym i nauce*. W związku z tym wnoszę o dopuszczenie pana magistra Grzegorza Tratkowskiego do dalszych etapów przewodu doktorskiego, prowadzących do nadania mu stopnia doktora nauk społecznych w dyscyplinie ekonomia i finanse.


Agata Kliber

Literatura

Bailey, D H, Borwein, J M, López de Prado, M, Zhu, QJ (2017) *The Probability of Backtest Overfitting*, Journal of Computational Finance 20(4), 39-69.

- Bailey, D H, López de Prado, M (2012) *The Sharpe Ratio Efficient Frontier*, Journal of Risk, 15(2), 3-44.
- Bailey, D H, López de Prado, M (2014) *The Deflated Sharpe Ratio: Correcting for Selection Bias, Backtest Overfitting and Non-Normality*, Journal of Portfolio Management, 40 (5), 94-107.
- Dionisio, A, Menezes, R, Mendes, D A (2004) *Mutual information: a measure of dependency for nonlinear time series*, Physica A 344 (1), 326–329.
- López de Prado, M. (2016), *Building Diversified Portfolios that Outperform Out-of-Sample*, Journal of Portfolio Management, 42 (4), 59-69.
- Lopez de Prado, M, Bailey, DH (2021) *The false Strategy Theorem: A Financial Application of Experimental Mathematics*, The American Mathematical Monthly, 128(9), 825-831.
- Miller, RG (1981) *Simultaneous Statistical Inference*, 2nd Ed. Springer Verlag New York.

Agata Kluber

