

Dr hab. Witold Orzeszko, prof. UMK
Katedra Zastosowań Informatyki i Matematyki w Ekonomii
Wydział Nauk Ekonomicznych i Zarządzania
Uniwersytet Mikołaja Kopernika w Toruniu

Recenzja pracy doktorskiej mgra Adama Chudziaka
„Time series events prediction using machine learning methods and the Efficient Market Hypothesis”
(„Przewidywanie wydarzeń w szeregach czasowych za pomocą metod uczenia maszynowego a Hipoteza Rynków Efektywnych”),
napisanej pod kierunkiem dra hab. Michała Ramszy, prof. SGH
w Kolegium Analiz Ekonomicznych Szkoły Głównej Handlowej w Warszawie

I. Formalne podstawy wykonania recenzji

Formalną podstawę napisania niniejszej recenzji stanowi pismo Przewodniczącego Rady Naukowej Dyscypliny Ekonomia i Finanse Szkoły Głównej Handlowej w Warszawie, prof. dra hab. Bogumiła Kamińskiego, z dnia 20.11.2020 r., informujące o powierzeniu mi roli recenzenta.

II. Ocena pracy

Recenzowana praca poświęcona jest zbadaniu przydatności metod uczenia maszynowego do prognozowania ruchów cen akcji, a w efekcie – do weryfikacji hipotezy o efektywności informacyjnej rynków papierów wartościowych.

Uczenie maszynowe (ang. *machine learning*, ML) jest dynamicznie rozwijającym się nurtem w zakresie obiecującej i bardzo popularnej obecnie dziedziny wiedzy, jaką jest sztuczna inteligencja. Rozwój ten jest pewną pochodną obserwowanej w ostatnich dekadach rewolucji informatycznej, skutkującej bezprecedensowym wzrostem mocy obliczeniowej komputerów i powstaniem nowych, bardziej efektywnych algorytmów przetwarzania danych. Jednocześnie wiele z dotychczasowych wyników badań empirycznych potwierdza skuteczność metod uczenia maszynowego w analizie danych rzeczywistych, w tym także ekonomicznych i finansowych szeregów czasowych. Ze względu na swój duży potencjał, metody te są nie tylko przedmiotem zainteresowania środowiska akademickiego, ale i coraz powszechniej stosowanym narzędziem w praktyce biznesowej. Oczywiście, tak jak w przypadku każdej nowej dziedziny wiedzy istnieje duże zapotrzebowanie na prowadzenie badań o charakterze naukowym, ukierunkowanych na konstruowanie nowych narzędzi i poprawę efektywności istniejących już metod, a także na rozwój leżącej u ich podstaw teorii.

Rozprawa doktorska mgra Adama Chudziaka wpisuje się w nurt bardzo istotnych i ciągle aktualnych badań nad efektywnością informacyjną rynków finansowych – koncepcji, której doniosłe znaczenie dla rozwoju finansów zostało potwierdzone przyznaniem nagrody im. Alfreda Nobla jej pionierowi – E. Farnie. Autor rozprawy skupia się na weryfikacji hipotezy o słabej efektywności rynków, analizując możliwość skutecznego prognozowania cen akcji. Jako narzędzia prognostyczne wykorzystuje metody uczenia maszynowego, a mówiąc ściśle –

trzy klasy sztucznych sieci neuronowych (perceptron wielowarstwowy – MLP, rekurencyjne sieci neuronowe – RNN oraz sieci głębokie – LSTM). Do transformacji prognozowanych szeregów czasowych Autor stosuje techniki przekształcania danych do reprezentacji wykorzystujących punkty istotne (ang. *landmark representation*), co – zgodnie ze sformułowaną hipotezą badawczą – może poprawić jakość wyznaczanych prognoz. Uważam, że wybrana tematyka, ze względu na jej duże walory zarówno naukowo-poznawcze, jak i aplikacyjne jest mocną stroną rozprawy.

Tytuł pracy jest moim zdaniem zbyt szeroki i nie do końca zrozumiały. Po pierwsze, sugeruje zastosowanie różnych metod uczenia maszynowego, podczas gdy w pracy wykorzystano w istocie wyłącznie sztuczne sieci neuronowe. Jak wiadomo, istnieje bardzo szeroka gama innych algorytmów ML, które można zastosować do prognozowania, np. metody oparte na analizie najbliższych sąsiadów, drzewa decyzyjne, techniki odwołujące się do koncepcji wektorów nośnych (np. SVM), czy metody łączenia algorytmów, takie jak np. lasy losowe, czy *bagging* i *boosting*. Po drugie, zbyt szeroko został określony przedmiot prognozowania, którym zgodnie z tytułem są szeregi czasowe. Czy rzeczywiście chodzi o dowolne szeregi czasowe? Szeregi finansowe, a zwłaszcza będące przedmiotem badań w pracy – szeregi cen instrumentów finansowych mają swoje specyficzne własności, w związku z czym wnioski otrzymane na podstawie ich badania nie powinny być uogólniane na inne szeregi ekonomiczne, nie mówiąc już o szeregach pozaekonomicznych. Po trzecie, nie wiadomo o jakie wydarzenia (ang. *events*) chodzi, co jest szczególnie enigmatyczne z racji, wspomnianego powyżej, braku informacji nt. badanych szeregów. Nie rozumiem dlaczego nie napisano w tytule wprost, że chodzi o prognozowanie ruchów (lub zmian) cen akcji.

W pracy nie przedstawiono jej celów, co uważam za istotne niedociągnięcie. Sformułowano natomiast hipotezę badawczą:

H: Certain financial markets do not satisfy the Efficient Markets Hypotheses.

oraz dwie hipotezy cząstkowe:

SH1: Machine learning techniques help forecasting events in financial time series, exposing undetected market inefficiencies.

SH2: Transformation of financial time series with representations using perceptually important points increases the machine learning forecast quality.

Hipotezy można uznać za poprawnie sformułowane, choć zważywszy na to, że w pracy poddano badaniu tylko jeden rynek – NYSE, można mieć wątpliwość, czy hipoteza główna nie została sformułowana zbyt szeroko.

Przyjętym hipotezom badawczym podporządkowana została struktura pracy i jej charakter teoretyczno-empiryczny. Praca została podzielona na pięć rozdziałów i zawiera dodatkowo: streszczenie, spis literatury, dwa załączniki oraz spisy tabel, rysunków i pseudokodów. Recenzowana praca liczy wraz z załącznikami 198 stron.

Dwa spośród rozdziałów to wstęp i zakończenie. Moim zdaniem na wyrost zostały one nazwane rozdziałami (pierwszym i piątym), co oznacza, że w istocie praca składa się z trzech rozdziałów zawierających jej zasadniczą treść.

W pierwszym z tych rozdziałów („*Efficient Market Hypothesis*”) przedstawiono hipotezę rynku efektywnego – jej istotę, genezę, teoretyczne podstawy oraz metody weryfikacji. Rozdział jest dobrze napisany i zawiera najważniejsze treści niezbędne do właściwego scharakteryzowania omawianej hipotezy.

Nie rozumiem, dlaczego Autor nie używa ani w tym rozdziale, ani w całej pracy terminu „efektywność informacyjna”, co jest de facto pełnym określeniem badanego zjawiska, powszechnie używanym w literaturze przedmiotu.

W podrozdziale 2.1.1 brakuje mi zdefiniowania pojęcia stopy zwrotu i opisu własności stóp zwykłych oraz logarytmicznych, który uzasadniłby decyzję Autora pracy, która z tych postaci będzie przedmiotem badania.

W podrozdziale 2.2 Autor pisze o badaniach nad korelacją i autokorelacją, nie wspominając o ważnym w ostatnich latach nurcie badań nad zależnościami o charakterze nieliniowym.

Mam wątpliwość, czy dyskusja dotycząca teoretycznych podstaw hipotezy rynku efektywnego przedstawiona w podrozdziale 2.2.4 powinna znajdować się w podrozdziale dotyczącym jej testowania. Moim zdaniem bardziej naturalne byłoby włączenie tej części do podrozdziału 2.1. Ponadto, nie rozumiem w jakim celu zostało napisane podsumowanie rozdziału. Nie wnosi ono nic nowego, a poza tym niepotrzebnie zaburza strukturę pracy (w pozostałych rozdziałach nie ma takich podsumowań).

W kolejnym rozdziale („*Methodology*”) zaprezentowano metody i algorytmy zastosowane w dalszej części pracy. Szczególny nacisk położono na metody reprezentacji wykorzystujące punkty istotne (podrozdział 3.2) oraz sztuczne sieci neuronowe (podrozdział 3.3). Ponadto w podrozdziale 3.5 opisano narzędzia oceny jakości prognoz. Nie rozumiem intencji Autora, dlaczego w tym rozdziale (w podrozdziale 3.4) zdecydował się na przedstawienie danych będących przedmiotem badania w pracy. Moim zdaniem struktura pracy zyskałaby na przejrzystości, gdyby oddzielić część metodologiczną od opisu przeprowadzonego badania empirycznego.

Mam zastrzeżenia dotyczące tytułu rozdziału. Określenie *Methodology* jest zbyt lakoniczne i z tego względu powinno zostać doprecyzowane. Uważam, że zgodnie z tytułem pracy powinien się tu znaleźć szeroki opis metod uczenia maszynowego, z podziałem na metody uczenia nienadzorowanego i nadzorowanego. Taki opis, choć może mniej szczegółowy, byłby potrzebny nawet w przypadku sugerowanego przeze mnie zawężenia tytułu (w którym doprecyzowano by, że chodzi wyłącznie o sieci neuronowe). Tymczasem w pracy można znaleźć tylko jeden akapit (str. 29), w którym Autor próbuje napisać o istocie uczenia maszynowego. To jest zdecydowanie za mało. W szczególności brakuje porównania wybranych przez Autora sieci neuronowych z innymi metodami uczenia maszynowego i wskazania argumentów uzasadniających ten wybór.

W rozdziale tym brakuje mi odniesienia do dwóch fundamentalnych problemów uczenia nadzorowanego: regresji i klasyfikacji. Właściwie dość długo trzeba się domyślać, czy Autor będzie budował model klasyfikacji czy regresji. Z jednej strony, formułuje problem badawczy w języku klasyfikacji (spadek czy wzrost ceny), a z drugiej – wprowadza ciągłą zmienną

objaśnianą (tj. stopę zwrotu), dla której odpowiedni jest model regresji. Ponadto, Autor nie wyjaśnia jakie są zalety wykorzystania modelu regresji do rozwiązywania problemu klasyfikacji. Czy nie lepiej byłoby od razu skonstruować model klasyfikacji?

W podrozdziale 3.2 pojawia się przykład dotyczący metod przekształcania danych do reprezentacji wykorzystujących punkty istotne (ang. *landmark representation*). Z niezrozumiałych dla mnie powodów omawianie przykładu nagle urywa się – bez zaprezentowania otrzymanych wyników i wniosków. Przykład jest następnie kontynuowany w podrozdziale 3.4 a jego wyniki zostają dopiero przedstawione w rozdziale 4.1. Dyskusyjna jest kwestia, w którym rozdziale powinien ten przykład się znaleźć, ale nie widzę powodu, żeby jego omawianie dzielić na trzy osobne fragmenty.

W podrozdziale 3.4 znajdują się informacje dotyczące analizowanych danych. Tak jak wcześniej napisałem, informacje te powinny się znaleźć w rozdziale dotyczącym badania empirycznego, przy czym powinny być poprzedzone przedstawieniem celu badania i opisaniem jego przebiegu. Brakuje mi głębszego uzasadnienia wyboru przedmiotu badania (dlaczego akurat NYSE i dlaczego akurat takie a nie inne akcje) oraz wstępnej analizy badanych cen i stóp zwrotów (np. wykresów czy wyników statystyki opisowej).

W podrozdziale 3.4 (str. 66) Autor napisał, że zastosował metodę przeszukiwania siatki (ang. *grid search*). Jednak nie jest jasne, w jaki sposób i do czego procedura ta została zastosowana. Czy, zgodnie z podstawowym jej celem, posłużyła do wyznaczenia metaparametrów modeli? Jeśli tak, to których i jakie wartości tychże metaparametrów zostały w procedurze rozważone?

W ostatnim spośród rozdziałów zawierających zasadniczą część pracy („*Results and discussion*”) przedstawiono wyniki badań empirycznych. Generalnie rozdział ma dużą wartość merytoryczną i ma kluczowe znaczenie w pozytywnej ocenie wartości niniejszej pracy.

W podrozdziale 4.1 przedstawiono wyniki ilustrujące zastosowanie metod przekształcania danych do reprezentacji wykorzystujących punkty istotne. Tak jak napisałem wcześniej, nie widzę powodu, aby zaproponowany przez Autora przykład dzielić na części znajdujące się w trzech różnych podrozdziałach. Ponadto, trzeba zaznaczyć, że ze względu na fakt, iż rozważono tylko jeden proces generujący, przeprowadzone badanie należy traktować raczej jako pewną ilustrację działania tych metod, a nie jako pełnoprawne symulacje. Wątpliwe jest zatem uogólnianie otrzymanych wniosków i traktowanie ich jako uniwersalne wskazania obowiązujące dla innych szeregów czasowych.

Podrozdział 4.2 zawiera wyniki prognozowania cen wybranych akcji z NYSE. Szkoda, że Autor od razu przystąpił do prezentacji wyników, nie wprowadzając czytelnika w istotę badania. Tak jak napisałem wcześniej, brakuje w tym podrozdziale części wstępnej zawierającej przejrzysty opis przedmiotu badania wraz z informacjami o jego celu, przebiegu i zastosowanych modelach benchmarkowych. W efekcie czytelnik musi domyślić się, że budowany będzie model regresji a nie klasyfikacji, nie ma też pewności w jaki sposób zostaną zastosowane metody przekształcania danych do reprezentacji wykorzystujących punkty istotne – do cen, czy do stóp zwrotu (po tabelą 3.2 pojawia się informacja o wyznaczeniu stóp zwrotu bez wyjaśnienia, czy zostały one obliczone na podstawie cen surowych, czy przekształconych). Brakuje też pogłębionej dyskusji nad kwestią długości horyzontu czasowego inwestycji na rynkach kapitałowych, która uzasadniłaby uznanie przyjętego przez Autora okresu jednego

miesiąca za długi termin. Nie wiadomo też, w jakim środowisku informatycznym zostały przeprowadzone badania.

Z uwagi na czytelność pracy, wiele szczegółowych rezultatów Autor zamieścił w załącznikach, natomiast w zasadniczej treści pracy przedstawił jedynie wyniki zagregowane. Jest to oczywiście poprawny zabieg, choć w wielu momentach można odnieść wrażenie, że wyniki zostały zagregowane w nadmiernym stopniu. Przykładem jest rysunek 4.11, gdzie dla każdej akcji przedstawiono połączone wyniki ze wszystkich modeli sieci neuronowych oraz ze wszystkich metod przekształcania danych. Choć szczegółowe wyniki znajdują się w tabelach w załączniku, to jednak Autor powinien w podrozdziale 4.2 dokładniej i obszerniej ocenić jakość poszczególnych modeli oraz poszczególnych metod przekształcania.

Na stronie 94 znajduje się sekcja *Portfolio variance*, która budzi moje trzy wątpliwości. Po pierwsze, dlaczego używać pojęcia „portfel”, skoro prognozowane są pojedyncze akcje? Po drugie, jakie ryzyko ma Autor na myśli pisząc, że zastosowane modele prowadzą do jego redukcji? Oczywiście wariancja rzeczywistych stóp zwrotu jest miarą ich ryzyka (a konkretnie – zmienności), ale o jakim ryzyku mówi wariancja wielkości prognozowanych (czyli teoretycznych)? Rodzi się tu kolejne pytanie – czy model, który dla każdego okresu wygeneruje wszystkie prognozy o tej samej wartości (czyli o zerowej wariancji) jest rzeczywiście taki dobry? Po trzecie, dlaczego fakt zmniejszenia się wariancji prognoz może wyjaśniać mniejszą dochodowość zastosowanych modeli w porównaniu ze strategią kupuj/trzymaj? Przecież dochodowość modeli zależy od tego, czy została na ich podstawie podjęta prawidłowa decyzja dotycząca dokonania zakupu bądź sprzedaży. Jednak decyzja ta zależy jedynie od znaku prognozy a nie od jej wartości, podczas gdy na wariancję wpływają przede wszystkim właśnie wartości prognoz.

Na str. 100 zaprezentowano wyniki testu Diebolda-Mariano, nie podano jednak, jaką przyjęto w nim postać funkcji straty.

W sekcji *Ensemble forecasts* (s. 101) wyjaśnienie, na czym polegała rozważona procedura prognozowania powinno znajdować się w tekście a nie w opisie tabeli (tabela 4.5). W tym miejscu rodzi się też pytanie, czy może warto by wyznaczyć łączoną prognozę nie poprzez głosowanie (ang. *hard voting*), lecz poprzez uśrednienie prognozowanej stopy zmian? Szkoda, że sformułowany wniosek, że zastosowana procedura łączona nie ma przewagi nad pojedynczymi predyktorami nie został poparty formalnym testem statystycznym.

Na str. 102 zostało sformułowane stwierdzenie, że z tabeli B.2 wynika, że zastosowane modele dały rezultaty gorsze niż prognoza naiwna. Tymczasem z analizy tabeli wynika wniosek przeciwny.

Samo badanie przeprowadzone zostało poprawnie. Mam pewne zastrzeżenia co do braku należytej dyskusji na temat specyfikacji budowanych modeli. W badaniu przyjęto *a priori* liczbę regresorów, parametry konstruowanych sieci neuronowych i parametry w metodach przekształcania danych do reprezentacji. Tymczasem, w literaturze przedmiotu znany jest fakt, że metody uczenia maszynowego są wrażliwe na dobór tych wielkości, dlatego proponuje się szereg metod optymalizujących ich wybór (np. metody oparte na walidacji krzyżowej). Metody te są niestety czasochłonne, jednak uważam, że Autor powinien – przynajmniej w jakimś zakresie – po nie sięgnąć. Generalnie jednak wyniki zaprezentowane w rozdziale 4.2 należy uznać za ciekawe i wartościowe. Pozwalają one na lepsze zrozumienie własności badanych szeregów, a przede wszystkim na ocenę możliwości ich efektywnego prognozowania za

pomocą uczenia maszynowego. Na wyróżnienie zasługuje fakt, że Autor otrzymane rezultaty próbuje konfrontować z uwarunkowaniami otoczenia ekonomicznego, w którym funkcjonował badany rynek, dzieląc analizowany okres na fazy wzrostu i spadku gospodarczego. Pragnę też pochwalić Autora za krytycyzm i ostrożność w formułowaniu wniosków dotyczących przydatności analizowanych metod. Dzięki temu Autor uniknął pewnej pułapki, w którą nieraz wpadają zwłaszcza młodzi naukowcy, próbujący – w narażający się na zarzut braku obiektywności sposób – przekonać o skuteczności metod, którymi się zajmują. Rozdział 4 zakończony jest częścią podsumowującą, w której w bardzo czytelny i merytorycznie poprawny sposób przedstawiono wnioski płynące z przeprowadzonych badań i ustosunkowano się do weryfikowanych hipotez badawczych. W części tej brakuje mi jedynie dokonania analizy porównawczej zastosowanych typów sieci neuronowych.

Spis literatury obejmuje 211 pozycji. Cytowane pozycje wskazują, że Autor w wystarczającym stopniu zapoznał się z literaturą przedmiotu. Pewien niedosyt może budzić brak pogłębionej dyskusji na temat dostępnych w literaturze wniosków z badań o charakterze metodologicznym (zwłaszcza w zakresie algorytmów uczenia maszynowego), które doprowadziły Autora do wyboru wykorzystanych w pracy narzędzi badawczych. Razi także brak najnowszych publikacji – wydanych po 2015 r., co szczególnie daje się zauważyć, gdy Autor dokonuje w pracy przeglądu literatury. W pracy brakuje również odniesienia do polskiej literatury przedmiotu, szczególnie w zakresie zastosowania uczenia maszynowego do polskiego rynku finansowego.

Wartość merytoryczną pracy oceniam pozytywnie. Dotyczy to zwłaszcza przeprowadzonych badań empirycznych, które umożliwiły weryfikację sformułowanych hipotez badawczych. Również formalna strona pracy jest poprawna. Praca napisana jest w języku angielskim i należy podkreślić, że pod tym względem została napisana bardzo dobrze. Generalnie, praca jest staranna i czytelna, choć jej walor podniosłoby poprawienie pewnych niedoskonałości. Oprócz wskazanych we wcześniejszej części recenzji uwag o charakterze ogólnym, przedstawiam poniżej również propozycje poprawek o charakterze bardziej szczegółowym:

- Streszczenie: Określenie „rozwój technologiczny” nie jest moim zdaniem najlepsze w odniesieniu do rozwoju metodologii analizy danych.
- Streszczenie: Nadmierne słowo: „(...) jednocześnie zachować zmniejszyć komponent (...)”.
- Streszczenie: Bardzo dziwny skrót myślowy: „przewidywalność jest trudna do zidentyfikowania”.
- Spis treści powinien uwzględniać również podrozdziały niższego poziomu (zgodnie z dokonaniem przez Autora podziałem tekstu).
- Spisy tabel, rysunków i algorytmów warto by przenieść na koniec pracy.
- Nazwy tabel i rysunków w spisach nie odpowiadają nazwom użytym w tekście.
- Str. 3 (po drugim akapicie): zbędne słowo „contains”.
- Str. 7 (pod wzorem 2.1): Powinno być F a nie f .
- Str. 18 (tytuł podrozdziału): Niepotrzebna duża litera na początku słowa „Technical”.
- Str. 35 (rys. 3.2): Zaprezentowane w legendzie linie wykresów są nieodróżnialne od siebie.

- Str. 35 (wzór 3.1): Czy po prawej stronie wzoru nie powinno być wartości bezwzględnej?
- Str. 44 (ogólna postać dekompozycji): W przypadku danych finansowych ważnym elementem dekompozycji jest również trend stochastyczny (jak rozumiem w sformułowanym wzorze został uwzględniony trend deterministyczny).
- Str. 48: Brak konsekwencji w zapisie słowa Perceptron (duża czy mała litera).
- Str. 50: Standardowym symbolem transpozycji jest duża litera T a nie mała.
- Str. 50: Czy $x_i \in R$? Jeśli tak, to w formule 3.11 argumentem funkcji f jest liczba rzeczywista, a nie element ze zbioru R^n . Podobny problem znajduje się na str. 54 we wzorze (bez numeru) poprzedzającym wzór 3.15. We wzorze tym po lewej stronie argumentem funkcji f jest n -wymiarowy wektor, a po prawej stronie – liczby rzeczywiste x_i .
- Str. 51 (pierwszy akapit): Warto by podać wzory wymienionych funkcji f .
- Str. 60: Pierwszy akapit kończy się przecinkiem.
- Str. 60: Przypis powinien kończyć się kropką.
- Str. 62: W opisie rys. 3.8 pojawił się symbol operatora \ominus zamiast \odot .
- Str. 66 (ostatnie zdanie drugiego akapitu): Powinno być „use” zamiast „used”.
- Str. 69: Brak konsekwencji w zapisie skrótu MMM (kursywą czy bez).
- Str. 69: Niepotrzebny przecinek na końcu zdania.
- Str. 70 (ostatnie zdanie): Czy Autor naprawdę miał na myśli estymację, czy może raczej regresję? Ponadto, warto by dodać o jaki błąd chodzi.
- Str. 83 (drugi akapit): Literówka w słowie „generally”.
- Str. 88: Bardzo niejasne i wymagające doprecyzowania zdanie „(...) all the representations are quite unpredictable”.
- Str. 94 (rys. 4.12): Jakie jednostki mają wartości na osi rzędnych?
- Str. 97 (trzeci akapit): Dwukrotnie słowo „with” w zdaniu „(...) level, with with p -values (...)”.
- Str. 98 (opis tabeli 4.3): Rażący skrót myślowy w sformułowaniu testowanej hipotezy: „(...) forecasting performance is not random (...)”.
- Spis literatury: W niektórych cytowanych pozycjach podane zostały pełne imiona a w niektórych tylko pierwsze litery.

Pragnę jednak podkreślić, że wymienione powyżej uwagi nie obniżają istotnie mojej pozytywnej oceny rozprawy.

III. Konkluzja

Praca wpisuje się w aktualny i bardzo potrzebny nurt badań nad metodami uczenia maszynowego, koncentrując się na ocenie ich przydatności do modelowania i prognozowania finansowych szeregów czasowych. Przeprowadzone badania należy uznać za oryginalne, o dużym znaczeniu naukowym i praktycznym. Mgr Adam Chudziak wykazał się ogólną wiedzą teoretyczną w naukach ekonomicznych w dyscyplinie ekonomia oraz umiejętnością samodzielnego prowadzenia pracy naukowej. Uwzględniając powyższe stwierdzam, że recenzowana praca doktorska pt. „Time series events prediction using machine learning

methods and the Efficient Market Hypothesis" („Przewidywanie wydarzeń w szeregach czasowych za pomocą metod uczenia maszynowego a Hipoteza Rynków Efektywnych”) spełnia wymogi ustawowe stawiane rozprawom doktorskim w dziedzinie nauk ekonomicznych w dyscyplinie ekonomia i wnoszę o jej dopuszczenie do publicznej dyskusji.

Toruń, 25 stycznia 2021 r.

Uibld Onerb