

Sopot 20.01.2021 r.

dr hab. Krzysztof Najman, prof. UG
Wydział Zarządzania Uniwersytetu Gdańskiego

Recenzja rozprawy doktorskiej
mgr. Adama Chudziaka

pt.: *Time series prediction using machine learning methods and the Efficient Markets Hypothesis*,
napisanej pod kierunkiem dra hab. Michała Ramszy, prof. SGH
w Kolegium Analiz Ekonomicznych Szkoły Głównej Handlowej w Warszawie

1. Przesłanki formalne napisania recenzji

Podstawę formalną przygotowania recenzji rozprawy doktorskiej pod w/w tytułem stanowią:

- uchwała nr 27 Rady Naukowej Dyscypliny Ekonomia i Finanse Szkoły Głównej Handlowej w Warszawie z dnia 04.11.2020 r.,
- ustawa o stopniach naukowych i tytule naukowym oraz o stopniach i tytule w zakresie sztuki z dnia 14 marca 2003 r. (Dz. U. 2003, Nr 65, poz. 595 z późn. zm. zawartymi w Dz. U. Z 2017 r., poz. 1789).

2. Konstrukcja merytoryczna rozprawy

a) problematyka badawcza, tytuł, cel rozprawy, metodyka badawcza oraz wykorzystana w rozprawie literatura przedmiotu

Problematyka badawcza rozprawy doktorskiej wpisuje się w prowadzoną od lat 70-tych ubiegłego wieku dyskusję nad Hipotezą Rynku Efektywnego (Efficient Markets Hypothesis, EMH). Praca koncentruje się na efektywności informacyjnej w swojej słabej formie. Zgodnie z tą hipotezą, bieżące ceny transakcyjne walorów notowanych na giełdzie papierów wartościowych zawierają w sobie wszystkie informacje kształtujące przeszłe i obecne poziomy cen jak i wolumenu. Gdyby hipoteza ta była prawdziwa, niemożliwe stałoby się prognozowanie przyszłych cen na podstawie cen przeszłych. Gdyby jednak prognozy takie były możliwe, byłby to argument świadczący o fałszywości EMH.

Mimo, że prac z tego zakresu prowadzonych na świecie, a także w Polsce jest ogromnie wiele, EMH nie została ostatecznie odrzucona. Podjęte przez doktoranta badania, z tego punktu widzenia oceniam za celowe.

Tytuł rozprawy budzi szereg wątpliwości. Jest nieprecyzyjny i wydaje się napisany slangiem analityków giełdowych. Określenie „*Time series event*” nie ma precyzyjnej definicji naukowej i nie wiadomo o jakie „wydarzenia” chodzi. Problem ten wyjaśnia się pośrednio dopiero po analizie całości przeprowadzonych badań. Podobnie: „*Time series*” to pojęcie ogólne i dotyczy każdego szeregu statystycznego indeksowanego czasem. Rozprawa dotyczy jednak konkretnie szeregów miesięcznych, logarytmicznych stóp zwrotu wybranych 9 walorów notowanych na NYSE. Za niefortunne uważam także użycie w tytule pojęcia „*Machine Learning*”, gdy Autor wykorzystuje w rzeczywistości kilka struktur sztucznych sieci neuronowych. Nieporozumieniem jest utożsamianie pojęcia „*Machine Learning*” z pojęciem „*Artificial Intelligence*”, z których to drugie jest znacznie szersze. ML skupia się na algorytmicznej implementacji pewnych koncepcji czy metod naukowych. Koncepcje te wymagają budowy aparatu pojęciowego, definicyjnego, metodycznego wraz z

 1

odpowiednimi założeniami, formalizmem matematycznym i określonymi dowodami (np. zbieżności, czy złożoności obliczeniowej). Te zagadnienia są domeną AI.

Cel główny rozprawy doktorskiej został sformułowany następująco: *This thesis aims to contribute to the EMH debate, the understanding of ML capabilities, and evaluation of methods in the interest of practitioners.* Poprawnie sformułowany cel pracy naukowej powinien determinować proces wnioskowania w niej zawarty. Jednak „udział w debacie” czy „zrozumienie możliwości” nie są celami prac naukowych. Trzeci element celu głównego, czyli „ocena metod” jest najbliższa temu co powinno być tu sformułowane, jednak Autor nie napisał, jakie metody chciałby poddać ocenie, z jakiego punktu widzenia, czy dla jakich zastosowań. Nie wiemy także o których praktyków chodzi. Tak sformułowany cel jest dla mnie zrozumiały dopiero po lekturze całej rozprawy, co nie powinno mieć miejsca w pracy naukowej.

Główna hipoteza badawcza, którą sformułował doktorant to: *„Certain financial markets do not satisfy the Efficient Markets Hypothesis.”*(str. 2). Tak sformułowana główna hipoteza badawcza budzi szereg wątpliwości. Niestety Autor nie sprecyzował, także w dalszej części pracy, co rozumie pod pojęciem „markets”. W rzeczywistości badany jest tylko jeden rynek - amerykański, a na tym rynku tylko 9 różnych walorów. Już z tego powodu badania doktoranta nie mogą mieć charakteru ogólnego. Jak wiadomo z licznych badań, poszczególne rynki, np. europejski, amerykański i japoński różnią się zauważalnie. Podobnie, nawet najbardziej przemyślany wybór 9 z kilku tysięcy spółek notowanych tylko na jednym parkiecie NYSE nie pozwoli na uogólnienie wyciągniętych wniosków. Nie jest także precyzyjnie zapisane, o którą postać EMH doktorantowi chodzi. Hipoteza ta, w najprostszym ujęciu, występuje w trzech wariantach ze względu na rodzaj efektywności i w trzech ze względu na jej stopień (natężenie). Z analizy tytułu, hipotez i treści wstępu rozprawy wnioskuję, że Autor bada informacyjną EMH w postaci słabej. Jednak czytając pracę dalej dowiadujemy się, że doktorant bada „efektywność techniczną”. Jest to pojęcie bardzo ogólne i występuje w bardzo wielu znaczeniach. Wyjaśnienie tej kwestii znajduje się dopiero na stronie 25, w końcowej części rozdziału pierwszego. Tu Autor wyjaśnia w jaki sposób rozumie to pojęcie i ostatecznie zapisuje: *„In this thesis, we will test the technical efficiency”*.

Wszystkie wskazane wyżej elementy skłaniają mnie do wyrażenia opinii, że główna hipoteza pracy doktorskiej została zapisana w sposób nieprecyzyjny, ze wszystkimi negatywnymi konsekwencjami tego stanu dla procesu wnioskowania.

Hipotezy pomocnicze SH1 i SH2 są sformułowane na podobnym stopniu ogólności.

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.”*

Określenie „*financial time series*” jest znacznie ogólniejsze niż szeregi miesięcznych stóp zwrotu, faktycznie badane w pracy. Podobnie, stosowanie w pracy określenia „*Machine learning techniques*” uważam, że słabo nieuzasadnione, ponieważ w rzeczywistości Autor korzysta jedynie z kilku wybranych struktur sztucznych sieci neuronowych.

Autor oparł swoje rozważania na bogatej literaturze tematu. Warto zauważyć, że przywołane zostały także prace podstawowe twórców opisywanych teorii. Pewien niedosyt budzi niewielka liczba aktualnych publikacji, w szczególności z zakresu sztucznych sieci neuronowych. Wiedza w tym zakresie rozwijają się bardzo dynamicznie i brakuje w części teoretycznej pracy odwołań do najnowszych koncepcji czy rozwiązań metodycznych. Brakuje także pozycji odnoszących się do badań polskiego rynku kapitałowego, które są przecież dość liczne i są istotnym głosem w dyskusji nad EMH.



Reasumując: doceniam wybór i ważność tematu. Po lekturze rozprawy doktorskiej rozumiem czego ona dotyczy i jakie badania doktorant przedstawia. Jednak tylko w niewielkim zakresie dowiedziałem się tego z tytułu rozprawy, celu i hipotez badawczych, a także opisu zawartego we wstępie do rozprawy. Świadczy to o jeszcze małej dojrzałości naukowej doktoranta.

b) układ i zawartość merytoryczna rozprawy

Praca składa się z pięciu rozdziałów w tym ze wstępu, dwóch rozdziałów zawierających rozważania teoretyczne, jednego rozdziału empirycznego i osobnego rozdziału zawierającego wnioski końcowe. Ten podział treści nie jest zbyt zręczny. Trzystronicowy *Preface* i niespełna dwustronicowe *Conclusion* nie są pełnoprawnymi rozdziałami i powinny być wyłączone z numeracji.

Rozdział drugi „*Efficient Markets Hypothesis*” jest wprowadzeniem do istoty EMH. Zawiera systematyczny przegląd koncepcji efektywności rynku, definicji tego zjawiska i badań nad jej pomiarem. Narracja jest prowadzona w sposób klasyczny, chronologicznie prezentując rozwój koncepcji efektywności rynku począwszy od prac Bacheliera i Fama kończąc na pracach z końca XX wieku i kilku z początku wieku XXI. Ze względu na obszerność badań w tym zakresie Autor musiał dokonać w prezentacji tych badań wielu wyborów, co jest uzasadnione. Sam wybór jest jednak zawsze subiektywny, a więc dyskusyjny. Autor pominął cały nurt badawczy dotyczący weryfikacji stochastycznej natury szeregów czasowych stóp zwrotu. Wielu autorów wskazuje, że równie złożone w swojej postaci i dynamice szeregi mogą być generowane przez procesy deterministyczne. O ile Teoria Chaosu nie przyjęła się szerzej w badaniach ekonomicznych to wydaje się, że nie obalono wielu argumentów świadczących o deterministycznej naturze przynajmniej części z szeregów czasowych stóp zwrotu walorów notowanych na wielu rynkach na świecie. W pracy brakuje także odniesień do polskiego rynku kapitałowego. Zupełnie pominięto liczne prace naukowców weryfikujące EMH na GPW w W-wie, czego nie uzasadnia fakt opisywania walorów notowanych na NYSE.

W rozdziale trzecim Autor podejmuje się opisu metod analitycznych, które zamierza wykorzystać w badaniu empirycznym. W konstrukcji pracy rozdział ten jest uzasadniony i znajduje się we właściwej części rozprawy. Rozdział zaczyna się od ogólnego wyjaśnienia podejścia Autora, do problemu analizy efektywności. Następnie znajduje się opis elementarnych struktur sztucznych sieci neuronowych, opis wykorzystanych do analizy danych i metod. W końcowej części rozdziału znajduje się opis metod oceny prognoz uzyskanych dzięki zastosowanym metodom. Konstrukcja taka jest moim zdaniem poprawna. Poruszone zostają wszystkie istotne elementy metodyczne. O ile do ogólnej konstrukcji i treści rozdziału nie mam zastrzeżeń, to w szczegółach pojawia się cały szereg wątpliwości czy elementów dyskusyjnych. W większości wynikają one z braku precyzji w formułowaniu niektórych treści, czasami z nadmiernych uproszczeń czy pominięć.

Wyjaśnienia Autora, że będzie badał prognozowalność szeregów logarytmicznych, miesięcznych stóp zwrotu, ponieważ EMH powinna być widoczna w długich okresach czasu, nie jest w tej części pracy wystarczająco uzasadniona. Opiera się ona na subiektywnej ocenie Autora, że inwestorzy rotują swoje portfele okresowo, zwykle ostatniego dnia miesiąca (str. 28). Wiadomo jednak z innych badań, że o ile taka częstotliwość rotacji portfela mogła być stosowana w drugiej połowie XX wieku, to już od kilkunastu lat tak nie jest. W szczególności od momentu, kiedy możliwe stało się inwestowanie algorytmiczne (automatyczne) inwestorzy rotują swoje portfele co kilka minut (w których nastąpiło tysiące transakcji i tyleż zmian cen). Doktorant w swojej pracy bada okres 1965 – 2015, który z tego punktu widzenia może nie być jednolity.



3

Podobnym uproszczeniem, czy wręcz skrótem myślowym jest opinia Autora (str. 30), że sztuczne sieci neuronowe „zdobyły popularność” po 1990 roku. Samo pojęcie „popularność” w kontekście nauki jest nieakceptowalne. Faktem jest jednak, że upowszechnienie się tych metod, głównie dla praktyki wymagało upowszechnienia się komputerów o wystarczającej mocy obliczeniowej. Jednak przed rokiem 1990 znane i stosowane były wszystkie istotne modele sztucznych sieci neuronowych. Także opisywane w rozprawie sieci RNN czy LSTM, są tylko ewolucją modeli znanych znacznie wcześniej. Ewolucja ta dotyczy zresztą głównie aspektów algorytmicznych, związanych z problemami optymalizacyjnymi i dostępnymi, nowymi rozwiązaniami informatycznymi.

Brakuje także nieco poważniejszego podejścia do podstaw matematycznych prezentowanych metod. Opisując algorytm wstecznej propagacji błędu uczenia sztucznych sieci neuronowych (str. 55-56) Autor opisał jedynie elementarny algorytm gradientowy. Jest to faktycznie algorytm podstawowy, jednak w praktyce nie stosowany, ponieważ są znane znacznie bardziej efektywne algorytmy. Brakuje choćby krótkiego przedstawienia głównych grup takich algorytmów, opisu ich własności, z których powinien wynikać wybór odpowiedniego algorytmu dla realizowanych w rozprawie celów. Brak takiej dyskusji naukowej nie pozwala ocenić z czego wynika wybór takiej a nie innej metody uczenia sieci ani czy wybór ten jest uzasadniony.

Podobnie, Autor prezentując sieci rekurencyjne RNN opisuje na stronach 57 - 60 rozwiązania, które będzie chciał wykorzystać w badaniu empirycznym, jednak głębiej nie uzasadnia tego wyboru. W szczególności nie odnosi się do własności podstawowych sieci rekurencyjnych a) Elmana i b) Hopfielda. Bez tego trudno wyjaśnić z jakiego powodu rekurencja zaproponowana przez Autora jest właściwym rozwiązaniem badanego problemu.

Na stronach 64-65 doktorant prezentuje elementarne informacje na temat zbioru danych, który będzie analizował. W jednym krótkim akapicie wyjaśnia, że analizie będzie poddanych 9 wybranych walorów notowanych na NYSE. Dowiadujemy się, że wyznaczone będą miesięczne i tygodniowe, logarytmiczne stopy zwrotu z cen zamknięcia. Braki danych nie będą imputowane. Dokonane będzie uciążlenie na dni bez notowań. Jest to chyba najslabszy fragment tego rozdziału. Weryfikując tak ważną dla rynku hipotezę, dobór danych i ich transformacje są sprawą kluczową. Brakuje niestety podstawowych wyjaśnień na jakiej podstawie dokonano wyboru spółek. Dlaczego 9? Dlaczego te konkretnie 9? Czy własności badanych szeregów czasowych się różnią? Czy spółki te są reprezentatywne dla pewnej części rynku? Jakie własności mają rozkłady badanych stóp zwrotu? Pytań takich chciałbym zadać wiele, niestety brak jest na nie odpowiedzi. Wydaje się, że jedynym kryterium była tylko ciągłość notowań tych spółek przez tak wiele lat. Jest to jednak kryterium czysto techniczne, a nie merytoryczne. Wyczuwam tu niesformułowane przez Autora założenie, że wszystkie szeregi stóp zwrotu są w identycznym stopniu prognozowalne, a więc wybór konkretnych walorów nie ma znaczenia. Założenie to wydaje się jednak niczym nie potwierdzone.

W końcowej części rozdziału trzeciego opisano metody weryfikacji uzyskanych prognoz. Nie podważając wyboru dokonanego przez Autora, podobnie jak wcześniej brakuje odniesienia się do teorii weryfikacji prognoz. W literaturze statystycznej i ekonometrycznej znanych jest wiele wskaźników jakości prognoz, począwszy od tych opartych na prognozach wygasłych, a kończąc na wskaźnikach opartych na modelach prognostycznych. Bez tych odniesień i szerszego wyjaśnienia dokonanego wyboru nie sposób ocenić w jakim stopniu został on dokonany świadomie i merytorycznie. Jakie zalety w stosunku do innych, powszechnie stosowanych metod oceny prognoz mają wybrane przez Autora wskaźniki?

Sam tytuł rozdziału trzeciego: „*Methodology*” wydaje się przesadnym uproszczeniem.



Rozdział czwarty składa się z trzech części. Pierwsza część zawiera wyniki badań Autora nad możliwością usunięcia czy też redukcji szumu losowego zawartego w badanych szeregach czasowych. Jego usunięcie mogłoby teoretycznie poprawić jakość prognoz, czyniąc sygnał podstawowy bardziej wyraźnym. W szczególności identyfikacja kierunku zmian wartości stóp zwrotu mogłaby być łatwiejsza. Procedura ta, nazwana przez Autora preprocesingiem jest w istocie jedną z wielu metod wygładzania szeregów czasowych, posiadającą tę zaletę, że nie zmienia wartości ekstremalnych, co w opinii doktoranta jest ważne. Druga część rozdziału czwartego to wyniki badań empirycznych nad możliwością predykcji badanych szeregów czasowych. Autor bada możliwości predykcji kierunków zmian (*directional accuracy*), stóp zwrotu z inwestycji (*retur on investment*), ogólną zdolność badanych modeli do generowania prognoz (*predictive ability*), wpływ wybranych procedur wygładzania szeregów na zdolność prognostyczną badanych modeli (*impact of representations on forecasts*), jakość prognoz uzyskiwanych przez zespoły metod (*ensamble forecasts*), zachowanie badanych modeli w okresach wzrostu i recesji gospodarczej w USA (*expansion vs recession period results*). Rozdział kończy się dyskusją i wnioskami z przeprowadzonych badań.

Konstrukcja empirycznego rozdziału czwartego jest poprawna, choć tylko częściowo związana z rozważaniami prowadzonymi przez doktoranta we wcześniejszych rozdziałach teoretycznych. W szczególności, w części teoretycznej Autor nie opisał żadnej ze strategii inwestycyjnych, w których chciałby wykorzystać uzyskane prognozy. Strategii takich jest potencjalnie nieskończenie wiele, a podanie tylko wartości wskaźnika ROI nie pozwala na żadną ocenę tej strategii. Oczywistym punktem odniesienia dla każdej z tych strategii jest podejście *buy and hold*. Niestety Autor swoją strategię inwestycyjną opisał tylko kilkoma słowami: „... *compares return of investment on portfolios using forecasts as buy/sell signals* ...” (str. 93). Podobnie oszczędnie dokonano opisu budowy prognoz zespołowych. W części teoretycznej Autor nie wyjaśnił czym są takie prognozy, w jaki sposób buduje się zespół metod prognostycznych, w jaki sposób uzyskuje się pojedynczą wartość prognozy na podstawie prognoz poszczególnych modeli, z czego wynika większa zdolność prognostyczna tego typu prognoz. Całe wyjaśnienie to jeden 9 linijkowy akapit, którego większa część to odnośniki do literatury, który niczego nie wyjaśnia.

Podobnie mało czytelny i niewystarczająco opisany jest fragment poświęcony jakości prognoz uzyskiwanych w okresach wzrostu i recesji. Autor nie przeprowadził żadnej analizy ekonomicznej, która uprawniałaby do podziału badanego okresu 1965 – 2015 na takie podokresy. Nie wyjaśnił przesłanek, dla których jakość prognoz mogłaby być jakościowo różna w tych podokresach. Całe wyjaśnienia mieszczą się w jednym, krótkim akapicie (str. 102) zawierającym jeden odnośnik do literatury.

Sposób prezentowania wyników badań empirycznych przez Autora jest w mojej ocenie mało czytelny i nieprzekonujący. Część informacji jest rozproszona w pracy. Przykładowo w tabelicy 4.3 (str. 98) przedstawiono wartości jednej statystyki testowej, której wartość mniejsza niż 0.05 wskazuje, że prognoza uzyskana daną metodą nie jest losowa. Nazwy modeli są zapisane skrótami np. MLP662+noRep. Dowiaduję się z tego, że to sztuczna sieć neuronowa, jednokierunkowa – warstwowa, o 3 warstwach ukrytych i liczbą neuronów w tych warstwach odpowiednio równej 6,6 i 2, a szereg nie był wygładzany. Jednak nie dowiem się, także z treści rozdziału, jak Autor ustalił taką a nie inną liczbę warstw i neuronów, ile jest danych wejściowych, jakim algorytmem wstecznej propagacji błędu sieć była uczona, jakie były parametry algorytmu uczenia sieci (a jest ich przynajmniej kilka), jakich funkcji aktywacji użyto w poszczególnych warstwach. Nie jest także nigdzie napisane jaki był zbiór uczący a jaki testowy, w jaki sposób dokonano podziału danych na te części. Brakuje także informacji o innych transformacjach danych, których dokonano (lub nie) przygotowując dane do analizy. Takie transformacje jak skalowanie na przedział o odpowiednich

granicach są często niezbędne ze względu na własności zastosowanych funkcji aktywacji w sieci. Wszystkie te szczegóły powinny być jednoznacznie zapisane przy prezentacji wyników.

Pracę kończy rozdział piąty, który zawiera sformułowane przez doktoranta wnioski z badań. Zebrane zostały cząstkowe wnioski z wcześniejszych punktów i stanowią podsumowanie badań.

c) uzyskane wyniki oraz wnioski z badań

Uzyskane w części empirycznej rozprawy wyniki są zgodne z wynikami uzyskiwanymi przez wielu badaczy na całym świecie. W zdecydowanej większości badanych przypadków odchylenia uzyskiwanych wyników od wyników czysto losowych są pomijalnie małe. Nawet te statystycznie istotne nie pozwalają na uzyskanie przewagi rynkowej ze względu na ich minimalną skalę. Nieco bardziej zachęcające wyniki osiągnięto w prognozowaniu kierunków zmian wartości stóp zwrotu, jednak wyniki nie są jednoznaczne. Autor zaobserwował, dobrze znane i badane przez ekonometryków od lat własności stochastyczne szeregów stóp zwrotu, polegające na grupowaniu się zmienności. W tej części badań Autor dostarczył kolejnych argumentów przemawiających za tym, że rynki są efektywne przynajmniej w ujęciu efektywności informacyjnej w swojej słabej formie. W tym zakresie wkład badań doktoranta do nauki oceniam jako niewielki. Ważniejsze, z naukowego punktu widzenia wydają się wyniki badań Autora nad możliwością wykorzystania badanych metod wygładzania szeregów czasowych do poprawy jakości prognoz. W wielu przypadkach poprawę jakości prognoz udało się zaobserwować, co jest wynikiem zachęcającym do dalszych badań. W tym zakresie wyniki przeprowadzonych badań empirycznych (przy wszystkich wyżej wymienionych zastrzeżeniach) uważam za wartościowe.

d) strona edytorska rozprawy

Strona redakcyjna pracy jest poprawna. Wszystkie rysunki, tablice, wzory są poprawnie numerowane i zatytułowane. Sposób cytowania literatury jest konsekwentny.

e) pozostałe uwagi

W pracy znajduje się przynajmniej kilka elementów, na które chciałbym zwrócić uwagę Autora. Po pierwsze brakuje mi w rozprawie elementów porządkujących pojęcia stosowane w rozprawie. Warto byłoby przeprowadzić dyskusję nad pojęciami takimi jak *Artificial Intelligence*, *Neural Networks*, *Deep Learning* czy zawarte już w tytule *Machine Learning*. Szczególnie to ostatnie jest zwykle błędnie definiowane przez młodszych naukowców. Na stronie 29 Autor wyraził następującą opinię: „*Machine Learning methods consist of a diverse group of learning mechanisms such as neural networks, decision trees, genetic algorithms, and many more.*”. W ogólności nie jest to opinia prawdziwa. Wszystkie wymienione metody są znacznie starsze niż ML, nie wszystkie są iteracyjne, nie wszystkie zawierają element uczenia, wiele z nich da się zastosować ręcznie (czy to będzie *Pencil Learning*?). W rzeczywistości jest to takie określenie, którego używa się potocznie do wskazania, że obliczenia wykonuje się na komputerze.

Podobnie brakuje dyskusji nad własnościami modeli opartych na sztucznej inteligencji. Nie sposób zgodzić się z kolejną opinią Autora (str. 29): „*We chose the artificial neural networks – poster boys of machine learning in the 21st century.*”. W kolejnych zdaniach Autor sugeruje, że modele te są niemal ostateczną odpowiedzią nauki na wyzwania XXI wieku. Tak jednak nie jest. Pozór ten wynika z prostego faktu, że publikuje się jedynie wyniki udanych eksperymentów z AI. Porażki są bez porównania częstsze

jednak nimi nikt się nie chwali. Jeden z badaczy tematu powiedział, że sztuczne sieci neuronowe są drugim z kolei, najlepszym sposobem rozwiązania niemal każdego problemu. Drugim – ponieważ pierwszym jest zawsze rozwiązanie analityczne, oparte na teorii, umieszczone w jej aksjomatach. Modele AI to tylko czarna skrzynka, dzięki której często uzyskujemy wartościowy wynik, która jednak nie wzbogaca naszej wiedzy o przyczynach czy relacjach w populacji. Wbrew pozorom nie daje się także rozwiązać każdego problemu przy ich pomocy. Przykładem jest nawet recenzowana rozprawa. Mimo zastosowania zaawansowanych metod sztucznej inteligencji nie udało się uzyskać prognoz pozwalających wygrać z rynkiem.

Nie jest także prawdą, że sieci warstwowe jednokierunkowe o większej niż dwóch warstwach ukrytych to sieci klasy *deep learning*, jak pisze Autor na stronie 52. W tej części rozdziału drugiego Autor kilkakrotnie ociera się o dyskusję nad własnościami warstw sieci MLP, jednak nie zdołał precyzyjnie sformułować swoich myśli. Można wykazać, że sieć MLP już o 2 warstwach ukrytych jest zdolna do aproksymacji dowolnej funkcji ciągłej z dowolną dokładnością. Może to jednak wymagać dużej liczby neuronów w tych warstwach. Można pokazać, że sieć MLP o większej niż 2 warstwach ukrytych, ale o niewielkiej liczbie neuronów w warstwie ma te same własności. Z tego powodu w niektórych zastosowaniach empirycznych bardziej praktyczne jest zastosowanie sieci o np. czterech warstwach ukrytych, ale np. tylko 20 neuronach w warstwie niż dwóch, ale po 100 neuronów. Sieć taka wymaga mniejszych zasobów i zwykle uczy się szybciej. Nie zmienia to jednak ostatecznych własności znalezionej rozwiązania ani własności samej sieci. *Deep learning* to jednak coś zupełnie innego niż sieć MLP o dużej liczbie warstw. Poza zupełnie innymi metodami uczenia takich sieci, same warstwy mają inną strukturę. Co więcej każda warstwa może mieć inną strukturę i funkcję. Często specjalizują się w rozpoznawaniu ściśle określonego wzorca (np. jedna warstwa - linie poziome, druga – pionowe, trzecia przekątne, itd.). Bardzo dobrym przykładem są tu sieci konwolucyjne. Z tego powodu uważam opis schematu *Figure 3.5* za błędny.

Tego typu dyskusji zabrakło w pierwszej części pracy.

W rozprawie jest więcej drobnych błędów, z których wymienię tylko dwa:

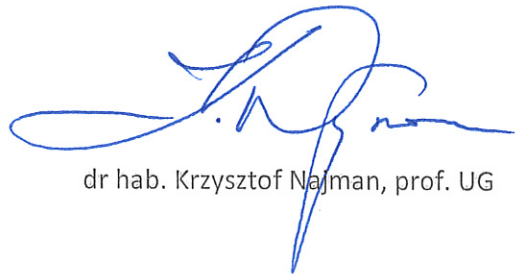
1. Na str. 31 – *Figure 3.1* – to nie jest schemat procesu predykcji nawet w najogólniejszym przypadku. W którym miejscu tego procesu jest definicja celu predykcji, ustalenie minimalnych wymagań dotyczących jakości prognoz, przygotowania/transformacji danych prognostycznych, wybór modelu. Co się dzieje, jeżeli prognozy są nietrafne? Ten schemat sprowadza się do wskazówki: weź dane, zrób prognozę i zobacz co wyszło.
2. Autor błędnie podaje datę powstania metody wstecznej propagacji błędu (str. 55). Metodę tę pierwotnie zaproponował w roku 1974 J. Werbos w swojej rozprawie doktorskiej (Werbos J., *Beyond regression. New tools for prediction and analysis in the behavioral sciences*. Ph.D. Harvard University.). Ponownie został „odkryty” przez E. Rumelharta, G.E. Hintoną i R.J. Wiliamsa w 1986 r., nie był więc powszechnie znany w latach 80-tych, jak napisał doktorant.

3. Konkluzja

Oceniając całość przedstawionych w rozprawie badań, mimo wyrażonych wyżej uwag doceniam pracę Autora. Rozprawa ma generalnie logiczną konstrukcję, proces wnioskowania oparty jest na sensownych przesłankach, proces analityczny z pewnymi mankamentami, ale jednak przeprowadzony jest zgodnie z regułami nauki. Uważam, że wyniki badań przedstawionych w pracy, choć nie mają waloru ogólnego są ciekawym głosem w dyskusji nad hipotezą efektywności rynku. Za szczególnie interesujące uważam badania nad zastosowaniem reprezentacji

wykorzystujących punkty istotne jako metody wygładzania szeregów czasowych, ułatwiających prognozowanie zjawisk tak dynamicznych jak stopy zwrotu z akcji. Doktorant wykazał się samodzielnością w prowadzeniu badań i podstawową umiejętnością dokumentowania prowadzonych badań.

Uważam, że recenzowana rozprawa spełnia wymogi stawiane pracy doktorskiej i wyczerpuje wymogi określone w art. 13 ust. 1 ustawy o stopniach naukowych i tytule naukowym oraz o stopniach i tytule w zakresie sztuki z dnia 14 marca 2003 r.: „...powinna stanowić oryginalne rozwiązanie problemu naukowego lub oryginalne rozwiązanie problem w oparciu o opracowanie projektowe, konstrukcyjne, technologiczne, lub oryginalne dokonanie artystyczne, oraz wykazywać ogólną wiedzę teoretyczną kandydata w danej dyscyplinie naukowej lub artystycznej oraz umiejętność samodzielnego prowadzenia pracy naukowej lub artystycznej”. (Dz. U. 2003, Nr 65, poz. 595 z późn. zm. zawartymi w Dz. U. Z 2017 r., poz. 1789). W związku z powyższym wnioskuję do Rady Naukowej Dyscypliny Ekonomia i Finanse Szkoły Głównej Handlowej w Warszawie o dopuszczenie Pana mgr. Adama Chudziaka do kolejnego etapu postępowania, tj. publicznej obrony.

A handwritten signature in blue ink, appearing to be 'K. Najman', written in a cursive style.

dr hab. Krzysztof Najman, prof. UG