

Łódź, dn. 27 lipca 2026 r.

Dr hab. inż. Jacek Kucharski, prof. PŁ.
Politechnika Łódzka
Instytut Informatyki Stosowanej

RECENZJA ROZPRAWY DOKTORSKIEJ

mgr. Sławomira Smyła

pt: „Methods for improving performance of neural network-based forecasting models”

1. Podstawa opracowania recenzji

Niniejsza recenzja została opracowana na zlecenie dr. hab. inż. Adama Kulawika, prof. PCz., Prodziekana ds. nauki Wydziału Informatyki i Sztucznej Inteligencji Politechniki Częstochowskiej, działającego na podstawie Uchwały Rady Dyscypliny Naukowej Informatyka Techniczna i Telekomunikacja Politechniki Częstochowskiej nr 20/2025/2026 z dnia 23 kwietnia 2026 r.

Przedstawiona do recenzji rozprawa została przygotowana pod merytoryczną opieką promotora – prof. dr. hab. inż. Grzegorza Dudka oraz dr. Pawła Pełki, jako promotora pomocniczego. Rozprawę doktorską stanowi zbiór ośmiu opublikowanych i powiązanych tematycznie artykułów naukowych, których Doktorant jest autorem lub współautorem, co wypełnia wymagania art. 187, ust. 3 ustawy z dnia 20 lipca 2018 r. Prawo o szkolnictwie wyższym i nauce (Dz. U. z 2021 r. poz. 478 z późn. zm.). Okres publikacji obejmuje lata 2019 ÷ 2026, a w skład cyklu wchodzi następujące pozycje:

- [D1] Smył S.: A hybrid method of exponential smoothing and recurrent neural networks for time series forecasting. *International Journal of Forecasting*, vol. 36(1), pp. 75-85, 2020.
- [D2] Smył S., Hua G.: Machine learning methods for GEFCom2017 probabilistic load forecasting. *International Journal of Forecasting*, vol. 35(4), pp. 1424-1431, 2019.
- [D3] Dudek G., Pełka P., Smył S.: A hybrid residual dilated LSTM and exponential smoothing model for mid-term electric load forecasting. *IEEE Transactions on Neural Networks and Learning Systems*, vol. 33, no. 7, pp. 2879-2891, 2022.
- [D4] Dudek G., Pełka P., Smył S.: 3ETS+RD-LSTM: A new hybrid model for electrical energy consumption forecasting. In: Yang H. et al. (eds) *Neural Information Processing. ICONIP 2020, LNCS*, vol. 12534, pp. 519-531, Springer, Cham, 2020.
- [D5] Smył S., Dudek G., Pełka P.: ES-dRNN: A hybrid exponential smoothing and dilated recurrent neural network model for short-term load forecasting. *IEEE Transactions on Neural Networks and Learning Systems*, vol. 35, no. 8, pp. 11346-11358, 2024.

- [D6] Smyl S., Dudek G., Pełka P.: ES-dRNN with dynamic attention for short-term load forecasting. In *2022 International Joint Conference on Neural Networks (IJCNN)*, Padua, Italy, 2022.
- [D7] Smyl S., Dudek G., Pełka P.: Contextually enhanced ES-dRNN with dynamic attention for short-term load forecasting. *Neural Networks*, vol. 169, pp. 660-672, 2024.
- [D8] Smyl S., Oreshkin B., Pełka P., Dudek G.: Any-quantile probabilistic forecasting of short-term electricity demand: Fusing uncertainties from diverse sources. *Information Fusion*, vol.127, part A, pp. 103637, 2026.

Dokumentacja uzupełniona jest ponadto liczącym 51 stron opracowaniem, mającym charakter przewodnika (dalej określanym mianem Przewodnika), w którym Doktorant przedstawił główne idee i osiągnięcia zawarte w poszczególnych publikacjach cyklu, umieścił je w czasowym kontekście prowadzonych badań, a także wskazał swój wkład w poszczególne publikacje współautorskie. Z informacji tych wynika, że 5 z 7 współautorskich publikacji zostało przygotowanych we współpracy wyłącznie z Promotorem i Promotorem pomocniczym, a w jednym przypadku zespół ten uzupełnia jeszcze jeden współautor. Analizując udział Doktoranta w poszczególnych pracach współautorskich widać, że w większości przypadków był On autorem głównych koncepcji prezentowanych modeli, wykonywał prace implementacyjne i weryfikacyjne, a także brał udział w przygotowaniu artykułów. Pozwala to uznać, że wkład mgr. S. Smyla w publikacje współautorskie jest znaczący i dotyczy kluczowych zagadnień w nich poruszanych. Przedstawiony cykl publikacji może więc być podstawą oceny indywidualnych osiągnięć mgr. S. Smyla w procedurze Jego ubiegania się o nadanie stopnia doktora. W powyższym Przewodniku Doktorant przedstawił też krótką charakterystykę 18 innych publikacji z lat 2010 ÷ 2025, których jest współautorem, a które uzupełniają Jego dorobek naukowy

2. Dobór tematu, cel i zakres pracy

Recenzowana rozprawa dotyczy interesujących naukowo i ważnych aplikacyjnie zagadnień z obszaru predykcji szeregów czasowych. W szczególności Doktorant skupił się na stworzeniu możliwości efektywnego wykorzystania sztucznych sieci neuronowych do zadań predykcji szeregów czasowych, wskazując słusznie na specyficzne cechy takiego problemu w porównaniu z zagadnieniami przetwarzania tekstów, obrazów lub dźwięków, w których z powodzeniem i na szeroką skalę wykorzystuje się metody uczenia maszynowego. Problematyka ta jest obecna w najnowszej literaturze przedmiotu, a artykuły cyklu zostały opublikowane w ciągu ostatnich siedmiu lat w czasopismach naukowych o wysokiej randze i na uznanych konferencjach, co świadczy o aktualności podjętej tematyki badawczej. Tematyka ta ma również ważne znaczenie praktyczne, szczególnie w kontekście rodzaju wykorzystywanych w badaniach danych (obciążenie sieci energetycznej i zużycie energii elektrycznej w krajach Europy) i ich roli w prognozowaniu procesów gospodarczych oraz konsekwencji finansowych.

Prezentując w rozdziale 1.1 Przewodnika przedmiot rozprawy mgr S. Smyl formułuje jej główny cel jako *„rozwój i eksperymentalną weryfikację rozwiązań poprawiających dokładność, stabilność i użyteczność metod predykcji bazujących na sztucznych sieciach neuronowych”*. Doktorant słusznie dostrzegł potrzebę prac nad efektywnym wykorzystaniem uczenia maszynowego w zagadnieniach predykcji szeregów czasowych, jako wartościowej alternatywy dla ugruntowanych metod statystycznych. Jednocześnie, określając zakres badań, Doktorant zwrócił uwagę na szczegółowe wyzwania podjętych prac, w tym konieczność zidentyfikowania kluczowych składników procesu predykcji i wskazanie sposobów ich realizacji odpowiadających specyfice tego procesu, zaprojektowanie możliwie uniwersalnych metod predykcyjnych łączących w sobie zalety klasycznych metod statystycznych i sztucznych sieci neuronowych, a także eksperymentalne wykazanie wyższości zaproponowanych rozwiązań nad dotychczas stosowanymi metodami. Wszystko to sprawia, że podjęte przez Doktoranta zadanie jest ambitne, wpisuje się w dyscyplinę naukową informatyka techniczna i telekomunikacja, jak również ma duży potencjał aplikacyjny, także w odległych od tej dyscypliny obszarach.

W moim przekonaniu wytyczone w rozprawie mgr. S. Smyla cele niewątpliwie stanowią wyzwanie odpowiadające rangą rozprawie doktorskiej, a uzyskane rozwiązanie stanowi oryginalne osiągnięcie Doktoranta.

Nawiązując do sformułowanego celu rozprawy Doktorant postawił następującą tezę:

„Jakość modeli prognostycznych opartych na sieciach neuronowych można poprawić poprzez odpowiednie przetwarzanie wstępne danych (tj. ich reprezentację), zastosowanie architektur dostosowanych do charakteru zadania, właściwie dobrane procedury uczenia oraz łączenie wielu modeli (ensembling).”

Nie mam większych wątpliwości, że przedstawione w rozprawie rezultaty pozwalają uznać taką tezę za udowodnioną, w szczególności w zakresie całości opracowanych rozwiązań i przyjętej koncepcji wykorzystania modeli neuronowych dla potrzeb predykcji szeregów czasowych. Trudno jednak oprzeć się wrażeniu, że teza ta została sformułowana nieco ogólnie i nieprecyzyjnie, co utrudnia jej w pełni przekonującą weryfikację. Przede wszystkim mówiąc o poprawie jakości modeli prognostycznych nie wskazano metody (lub metod), względem których ta poprawa miałaby nastąpić. Z treści rozprawy wynika, że Doktorant porównuje proponowane przez siebie rozwiązania zarówno z klasycznymi statystycznymi metodami prognostycznymi, jak i z tymi wykorzystującymi uczenie maszynowe. Można domniemać, że Doktorantowi chodzi o stopniową poprawę jakości Jego własnych specyficznych rozwiązań neuronowych poprzez dodawanie i rozwój elementów

wymienionych w drugiej części tezy, ale wtedy mówienie ogólnie o „modelach prognostycznych opartych na sieciach neuronowych” jest także nie do końca uprawnione.

W moim odczuciu kluczowym problemem jaki mgr S. Smyl rozwiązuje w rozprawie jest rozwój i badanie możliwości wykorzystania modeli neuronowych w zadaniu predykcji szeregów czasowych, i w tym kontekście upatruję głównych osiągnięć Doktoranta w zakresie dyscypliny naukowej informatyka techniczna i telekomunikacja, w której prowadzone jest postępowanie o nadanie Mu stopnia naukowego doktora.

Pozytywnie oceniam kompletność rozprawy, w której Doktorant przedstawił w szczególności:

- wyczerpujące odniesienie się w poszczególnych artykułach cyklu do stanu wiedzy w obszarach bezpośrednio związanych z rozprawą oraz w zakresie szczegółowych zagadnień poruszanych w danym artykule, tj. metod predykcji szeregów czasowych, modelowania statystycznego oraz metod uczenia maszynowego;
- propozycje autorskich, tworzonych i prezentowanych przyrostowo w kolejnych artykułach cyklu, rozwiązań w zakresie poprawy jakości tworzonych neuronowych modeli predykcyjnych, a także ich praktycznej implementacji;
- weryfikację eksperymentalną proponowanych metod z wykorzystaniem rzeczywistych danych i ich szeroką analizę porównawczą oraz wartościowe studia ablacyjne poszczególnych rozwiązań.

W mojej opinii składający się na rozprawę cykl publikacji wraz z załączonym Przewodnikiem stanowią więc całościowe opracowanie z wyraźnie postawionym celem i konsekwentną jego realizacją.

3. Merytoryczna ocena rozprawy i uzyskanych wyników

Wprowadzeniem do badań prowadzonych przez mgr. S. Smyla są przedstawione w [D1] i [D2] koncepcje włączania metod uczenia maszynowego w systemie predykcyjnym szeregów czasowych oraz łączenia ich z klasycznymi metodami statystycznymi, jak Exponential Smoothing (ETS). Autor zaproponował różne konfiguracje tego typu struktur od wykorzystania w [D2] rodziny drzew decyzyjnych oraz wielowarstwowych preceptronów w połączeniu z prostym mechanizmem usuwania sezonowości (escape seasonality trick), po połączenie wygładzania wykładniczego (ETS) z rekurencyjnymi sieciami neuronowymi w [D2]. Prace te z punktu widzenia wkładu w dyscyplinę naukową informatyka techniczna i telekomunikacja należy postrzegać raczej jako propozycje efektywnego łączenia znanych

lub nieznacznie zmodyfikowanych metod, aniżeli w pełni oryginalnych nowych rozwiązań informatycznych. Ich ważną zaletą jest jednak wytycznie pewnego trendu dotyczącego hybrydowych metod predykcji szeregów czasowych, potwierdzonego wysokimi lokatami jakie te rozwiązania uzyskały w uznanych w środowisku zawodach metod predykcyjnych. Rozwiązanie przedstawione w [D1] uzyskało w 2018 r. pierwsze miejsce w M4 Competition, zawodach organizowanych cyklicznie od 1982 r. przez prof. Makridakisa, który to wynik uznano w konkluzji tych zawodów jako nowy obiecujący kierunek rozwoju metod predykcji. Z kolei metoda opisana w [D2] zajęła trzecie miejsce w sesji kwalifikacyjnej Global Energy Forecasting Competition w 2017 r.

Główny ciąg przeprowadzonych przez Doktoranta badań został udokumentowany w pracach [D3 ÷ D8], gdzie w sposób przyrostowy przedstawiono kolejne etapy rozwoju metod predykcyjnych z wykorzystaniem sztucznych sieci neuronowych oraz ich weryfikację dla potrzeb średnio i krótkoterminowej predykcji obciążenia sieci i zużycia energii elektrycznej w 35 krajach europejskich.

W [D3], oprócz wstępnego przetwarzania danych (preprocessing) realizowanego z wykorzystaniem wygładzania wykładniczego (ETS), Doktorant włączył do modelu warstwę specjalizowanych komórek rekurencyjnych sieci neuronowych w postaci tzw. Residual Dilated Long-Short Term Memory, inspirowanych znanym z popularnego modelu ResNet mechanizmem tzw. shortcut (gdzie wejście określonego bloku (warstwy) podawane jest w addytywny sposób na jego wyjście). Pewnego typu nowością zaproponowanego rozwiązania jest wprowadzenie trzypoziomowego uczenia zespołowego (ensembling), jako metody regularyzacji modelu. Ponadto parametry bloków rekurencyjnych oraz wygładzania wykładniczego są optymalizowane algorytmem stochastycznego spadku gradientu (Stochastic Gradient Descent – SGD), co również wpływa na poprawę jakości predykcji. Zaproponowane przez mgr. Smyła rozwiązanie zostało pozytywnie zweryfikowane poprzez porównanie z kilkunastoma innymi rozwiązaniami należącymi do klasycznych w zakresie predykcji szeregów czasowych, a także okazało się porównywalne z innymi metodami wykorzystującymi ETS. Ciekawym elementem zaprezentowanych badań są przeprowadzone przez Doktoranta studia ablacyjne, wskazujące na istotną rolę autorskiego preprocessingu oraz metody łączenia komórek rekurencyjnych, a ograniczoną rolę uczenia zespołowego.

Nowym elementem wprowadzonym przez mgr. Smyła w kolejnej wersji modelu predykcyjnego przedstawionej w [D4] jest wstępna normalizacja analizowanych szeregów czasowych, polegająca na usunięciu trendów i ujednoliceniu wariancji. Operację tę przeprowadzono w stosunkowo prosty sposób wykorzystując wartości średnie i odchylenia standardowe wyznaczone dla podzbiorów danych obejmujących roczne okresy obserwacji.

Ten prosty zabieg, w połączeniu z denormalizacją wyników modelu rekurencyjnego przeprowadzaną z wykorzystaniem metody ETS, pozwolił nieco poprawić dokładność predykcji systemu w porównaniu z zaprezentowanym w [D3], na tym samym zbiorze danych.

W [D5] Doktorant przedstawił sposób wykorzystania opracowanego przez siebie systemu predykcyjnego do tworzenia krótkoterminowych prognoz zużycia energii elektrycznej. Mgr Smyl wskazuje na szczególne cechy prognozowania krótkoterminowego (obejmującego od jednej godziny do kilku dni) w porównaniu z prognozowaniem średnioterminowym (w zakresie kilku miesięcy do roku), tj. nieliniowe trendy danych, różnorodna ich sezonowość, zmienna wariancja i losowe fluktuacje, a następnie proponuje kolejne, adekwatne modyfikacje swoich rozwiązań stanowiące odpowiedź na te specyficzne wymagania. Główną nowością zaprezentowanego w [D5] rozwiązania jest wprowadzenie adaptacyjnej modyfikacji współczynników wygładzania wykładniczego (ETS). Modyfikacja ta przeprowadzana jest w każdym kroku rekurencyjnym, a odpowiednie składniki korekcyjne wyznaczone są jako dodatkowe elementy wektora wyjściowego części rekurencyjnej modelu. Oprócz wyczerpującej weryfikacji eksperymentalnej i porównania zaproponowanego rozwiązania w ramach szerokiej rodziny innych metod, Doktorant przeprowadził po raz kolejny ciekawe studia ablacyjne, wskazujące na rolę poszczególnych składowych systemu.

Jednym z ciekawszych i bardziej wartościowych rozwiązań zaproponowanych przez mgr. S. Smyla, w prezentowanym przez Niego toku rozwoju neuronowych metod predykcji szeregów czasowych, jest przedstawiona w [D6] idea włączenia w procedurę przetwarzania danych mechanizmu *attention*, będącego kluczowym elementem współczesnych modeli językowych, który w sposób efektywny pozwala uwzględnić informację kontekstową. Doktorant zaproponował uzupełnienie modelu przedstawionego w [D5] o mechanizm *attention* w formie dodatkowego ważenia iloczynem Hadamard'a wektora wejściowego $\mathbf{x}_t$ drugiej warstwy rekurencyjnej przez wektor *attention* $\mathbf{m}_t$, wygenerowany jako wyjście pierwszej warstwy rekurencyjnej modelu. W ten sposób uwzględniona zostaje w dalszym przetwarzaniu „siła” poszczególnych składowych wejścia w sensie ich kontekstowego znaczenia w przetwarzanej sekwencji. Na etapie weryfikacji eksperymentalnej wykazano przewagę zaproponowanego rozwiązania w stosunku do wszystkich analizowanych metod, w tym wcześniejszych wersji autorskich modyfikacji.

Kolejnym krokiem w rozwoju proponowanej przez Doktoranta rodziny metod predykcyjnych jest dodanie w [D7] w strukturze modelu dodatkowego kanału przetwarzania (ścieżki kontekstu), wprowadzającego do modelu predykcyjnego globalną informację o charakterze przetwarzanych sekwencji. Struktura i elementy składowe tego kanału są takie same jak głównego kanału przetwarzania, z tym, że informacja wyjściowa ścieżki kontekstu, będąca

odpowiednio przetworzonym wektorem r_t dla całego zbioru wsadowego, jest wprowadzona w formie konkatencji do wektora wejściowego x_t głównego kanału przetwarzania. Weryfikacja eksperymentalna dowiodła wyższości proponowanego rozwiązania w rozumieniu większości analizowanych metryk jakościowych, a studium ablacyjne potwierdziło istotną rolę kanału kontekstowego i sposobu przetwarzania informacji kontekstowej w uzyskaniu wysokiej jakości predykcji krótkoterminowej. Należy jednak zauważyć, że w przypadku raportowanych w [D7] badań rozszerzono horyzont czasowy danych treningowych (do okresu 2006-2018, a nie jak wcześniej 2016-2018), jednak dane te okazały się niekompletne w całym przekroju czasu i regionów geograficznych, stąd nie wszystkie porównywane z zaproponowanym rozwiązaniem metody działały w tych samych warunkach, i w konsekwencji przedstawiona weryfikacja nie jest do końca wiarygodna (szczególnie, że jak wynika z analizy ablacyjnej długość okresu treningowego ma istotny wpływ na jakość predykcji).

Nieco odrębnym elementem serii publikacji stanowiących składowe rozprawy doktorskiej mgr. S. Smyła jest [D8], w którym podano probabilistyczne ramy metodyczne generowania predykcji kwantylowych dla dowolnego zestawu kwantyli, na podstawie jednego wytrenowanego modelu. W pracy wykorzystano opracowane wcześniej modele neuronowe z rodziny ESRNN (Exponential Smoothing Recurrent Neural Network) autorstwa mgr. S. Smyła oraz modele N-BEATS (Neural Basis Expansion Analysis for Time Series), których twórcą jest B.N. Oreshkin – współautor artykułu [D8]. Zaproponowana metodyka polega na wprowadzeniu do procesu uczenia predykcyjnego modelu neuronowego dodatkowej informacji o generowanym losowo poziomie kwantylowym predykcji, zarówno na wejście modelu jak i do funkcji straty. Tak wytrenowany model jest w stanie wygenerować na etapie wnioskowania predykcję dla dowolnego zadanego kwantyla. Wykazano i uzasadniono również, że korzystniej jest wykorzystywać nierównomierną funkcję gęstości prawdopodobieństwa, z której losuje się wartości kwantyli na etapie treningu (np. rozkład Beta). Sama koncepcja podejścia przedstawionego w [D8] została zaczerpnięta z literatury, ale Autorzy (w tym Doktorant) wprowadzili do niej istotne modyfikacje, tworząc podejście znacząco rozszerzające możliwości wykorzystania modeli neuronowych w probabilistycznym prognozowaniu szeregów czasowych.

W podsumowaniu Przewodnika (rozd. 12) mgr S. Smył przedstawił krótko najważniejsze aspekty przeprowadzonych badań, opracowane autorskie rozwiązania oraz wskazał na najważniejsze uzyskane wyniki. Pewną słabością tej części rozprawy jest brak precyzyjnego odniesienia się do postawionej na jej wstępie tezy. W kontekście celu rozprawy i tezy badawczej warto było jednoznacznie wskazać osiągnięcia i wyniki będące dowodem prawdziwości tezy.

4. Uwagi krytyczne i dyskusyjne

Recenzowana rozprawa nie jest pozbawiona fragmentów budzących pewne wątpliwości lub rodzących określone pytania.

1. Wszystkie zaprezentowane modele charakteryzują się stosunkowo złożoną strukturą, szczególnie w porównaniu z klasycznymi rozwiązaniami, co sam Doktorant kilkakrotnie stwierdza w przedstawionych publikacjach. W tym kontekście szczególnie ważny wydaje się być przebieg procesu uczenia poszczególnych modeli, jego zbieżność oraz ewentualna skłonność do przeuczania się. Czy tego typu analizy były prowadzone, szczególnie w kontekście ilości dostępnych danych treningowych?
2. Weryfikacja eksperymentalna opracowanych modeli została przeprowadzona w różnym ujęciu na monotematycznych danych dotyczących obciążenia sieci energetycznej i zużycia energii elektrycznej. Czy Doktorant próbował zastosować swoje rozwiązania do szeregów czasowych opisujących inne dziedziny, np. dane finansowe, pogodowe itp., co stanowiłoby jednoznaczne potwierdzenie uniwersalności zaproponowanych modeli, wobec stosunkowo dużego komponentu heurystycznego zawartego w poszczególnych rozwiązaniach? Czy w przypadku innych dziedzin Doktorant widzi potrzebę wprowadzenia specyficznych modyfikacji strukturalnych lub metodycznych swoich rozwiązań?
3. W modelu opisanym w [D5] wprowadzono dynamiczne korygowanie współczynników wygładzania wykładniczego (ETS), w każdym kroku rekurencyjnym, jako sposób dopasowania modelu do specyfiki prognoz krótkoterminowych. Jaka była motywacja wprowadzenia takiego mechanizmu właśnie w tym przypadku i czy mógłby on być skuteczny również dla innego typu prognoz (średnio lub długoterminowych)? Czy dynamiczna korekta w formie wstecznego strumienia informacji miała wpływ na stabilność prowadzonych obliczeń i zbieżność procesu uczenia modelu?
4. Jak należy rozumieć mało znaczący wpływ zastosowania rekurencyjnych komórek dRNNCell zaproponowanych jako autorskie rozwiązanie w [D5] w porównaniu do klasycznego LSTM, na co wskazuje przypadek Ab6 przedstawiony w studium ablacyjnym tego artykułu?
5. Jaka jest interpretacja wektora *attention*, m_t , generowanego przez pierwszą komórkę rekurencyjną modelu predykcyjnego przedstawionego w [D6], w sensie wprowadzania informacji kontekstowej do przetwarzanego wektora wejściowego x_t ? Czy istniałaby możliwość realizacji mechanizmu *attention* w wyższych warstwach przetwarzania zaproponowanego rekurencyjnego modelu predykcyjnego?

5. Wniosek końcowy

Recenzowana rozprawa doktorska mgr. Sławomira Smyła w mojej ocenie zawiera oryginalny dorobek jej Autora w dyscyplinie informatyka techniczna i telekomunikacja, w tym w szczególności w zakresie projektowania i analizy zaawansowanych modeli prognozowania szeregów czasowych z wykorzystaniem uczenia maszynowego. Jednocześnie uznaję uzyskane wyniki jako wartościowe aplikacyjnie, szczególnie w ważnym dla gospodarek poszczególnych krajów zakresie precyzyjnego przewidywania obciążenia sieci energetycznej i zużycia energii elektrycznej. Doktorant wykazał się dobrym poziomem wiedzy w zakresie objętym rozprawą, tj. uczenia maszynowego, metod statystycznych oraz przetwarzania szeregów czasowych. Krytyczne uwagi sformułowane w recenzji nie zmieniają mojej całościowej pozytywnej opinii nt. rozprawy.

Podsumowując stwierdzam, że rozprawa doktorska mgr. Sławomira Smyła spełnia wymagania określone w art. 187 ustawy z 20 lipca 2018 r. Prawo o szkolnictwie wyższym i nauce, i wnoszę o dopuszczenie jej Autora do publicznej obrony.