

---

Dr hab. inż. Wojciech Kotłowski, prof. PP  
Instytut Informatyki Politechniki Poznańskiej  
ul. Piotrowo 2, 60-965 Poznań  
tel: (+48) 61 665 2936  
wkotlowski@cs.put.poznan.pl

---



Poznań, 1 lutego 2025 r.

## Recenzja rozprawy doktorskiej

mgr inż. Łukasza Lepaka

*Task automation using artificial intelligence methods*

### **Problem badawczy podejmowany w pracy**

Rozprawa doktorska Łukasza Lepaka pt. *Task automation using artificial intelligence methods* podejmuje niezwykle aktualny i istotny temat w dziedzinie uczenia maszynowego – automatyzację zadań za pomocą metod sztucznej inteligencji. W obliczu dynamicznego rozwoju technologii informacyjnych oraz ich rosnącego wpływu na różne dziedziny życia i gospodarki, efektywne wykorzystanie sztucznej inteligencji do automatyzacji procesów staje się jednym z kluczowych wyzwań współczesnej inżynierii i technologii.

Praca obejmuje dość szeroki zakres zastosowań głębokiego uczenia maszynowego oraz uczenia ze wzmocnieniem, przedstawiając sposób automatyzacji czterech różnych zadań: handlu energią elektryczną na rynku dnia następnego, wykrywania słów kluczowych w nagraniach audio dla języka polskiego (jako przykładu języków niskozasobowych, tzn. z małą ilością dostępnych danych), przyrostowej optymalizacji hiperparametrów w metodach uczenia sieci neuronowych, oraz symultanicznego tłumaczenia maszynowego. W tym ostatnim przypadku Autor proponuje również nową komórkę rekurencyjną, która pozwala na głęboką transformację stanu i jest odporna na problemy związane z propagacją gradientu.

Przedstawione w pracy rozwiązania mają istotne znaczenie zarówno z punktu widzenia naukowego, ponieważ każde z rozwiązań jest równocześnie propozycją nowego, autorskiego algorytmu, jak i z praktycznego punktu widzenia, gdyż każde z rozwiązań weryfikowane jest na rzeczywistych zbiorach danych w obszernych eksperymentach obliczeniowych.

## Struktura pracy i cele badawcze

Rozprawa jest napisana bardzo dobrym językiem angielskim, liczy 151 stron i składa się z 9 rozdziałów oraz szeregu załączników. Ma charakter syntezy treści pięciu powiązanych ze sobą tematycznie artykułów naukowych, które opisane są w rozdziałach 3-7, oraz załączone do pracy w oryginalnej formie w załącznikach B.1-B.5. Rozdział pierwszy stanowi wprowadzenie do tematyki badań, oraz zbiorcze przedstawienie hipotez badawczych wraz z opisaniem wyników, a także przedstawia listę publikacji wraz ze wskaźnikami bibliograficznymi (punkty MNiSW, współczynnik *Impact Factor*, procentowy wkład Autora rozprawy). W rozdziale drugim zawarto podstawy teoretyczne, dotyczące uczenia ze wzmocnieniem (przedstawienie problemu, definicje podstawowych pojęć, lista najbardziej popularnych algorytmów z podziałem na typy), architektur sieci neuronowych (sieci gęste, autoenkodery, sieci rekurencyjne – w tym LSTM i GRU, metodykę Seq2Seq – w tym architektury encoder/decoder i transformer, architektury uczenia się metryk podobieństwa – sieci syjamskie i sieci prototypowe), metod uczenia sieci neuronowych (w tym klasycznego SGD, metod z członem „pędu” (*momentum*) takich jak CM, NAG, oraz metod adaptacyjnych - AdaGrad, RMSProp, Adadelta, a także – zapewne najpopularniejszej z nich – Adam). Rozdział 8 to podsumowanie, a rozdział 9 opisuje inne osiągnięcia doktoranta, nie stanowiące wkładu w rozprawę doktorską.

Podsumowując, Doktorant starannie opisał i dobrze umotywowował dziedzinę badawczą, zamieścił obszerny opis podstaw teoretycznych, streścił każdą z załączonych prac i zawarł również wszystkie potrzebne dane bibliograficzne dotyczące publikacji. Ponieważ struktura pracy jest w zasadzie podporządkowana „publikacyjnemu” charakterowi rozprawy, trudno mieć do niej zastrzeżenia.

Głównym celem pracy była automatyzacja zadań. Pod tym bardzo obszernym tematem kryje się kilka konkretnych hipotez badawczych, wymienionych przez Autora we wprowadzeniu:

1. Automatyzacja tworzenia ofert w handlu energią na rynku dnia następnego prowadzi do zwiększenia zysków handlującego i prowadzi do strategii możliwej do zastosowania w rzeczywistych scenariuszach.
2. Wyszukiwanie słów kluczowych w nagraniach z centrów obsługi w języku niskozasobowym może zostać przeprowadzone przy użyciu modeli dopasowujących nagrania przy użyciu miar podobieństwa.
3. Krótko- i długoterminowy wpływ hiperparametrów algorytmu uczącego się na proces treningowy można wykorzystać do ich dynamicznej optymalizacji bez wcześniejszej znajomości rozwiązywanego problemu.
4. Opóźnienie tłumaczenia w symultanicznym tłumaczeniu maszynowym może być automatycznie kontrolowane przy jednoczesnym utrzymaniu wysokiej jakości tłumaczenia dla sekwencji o dowolnej długości.
5. Głęboka, ogólna transformacja stanu w rekurencyjnej sieci neuronowej pozwala osiągnąć wyniki porównywalne z metodami *state-of-the-art*, jednocześnie ułatwiając proces uczenia i zapewniając efektywne wykorzystanie pamięci.

Do każdej z hipotez przyporządkowana jest jedna z pięciu załączonych publikacji.

Trudno w tym momencie nie zwrócić uwagi na stosunkowo niewielkie powiązanie tematyczne samych prac. Autorowi udało się znaleźć „wspólny mianownik” w postaci problematyki automatyzacji zadań, ale robi on jednak wrażenie dodanego trochę sztucznie, w celu spięcia prac w jedną rozprawę. Same prace dotyczą dziedzin tak różnych jak handel algorytmiczny, przetwarzanie języka naturalnego czy optymalizacja hiperparametrów. Z mojej perspektywy nie stanowi to jednak istotnego problemu. Proces prowadzenia badań naukowych jest trudny do odgórnego zaplanowania, a jego kierunek zmienia się często w sposób ciężki do przewidzenia na etapie konstruowania planu badawczego. Dodatkowo, dorobek naukowy obejmujący tak wiele różnych dziedzin świadczy na korzyść wiedzy i umiejętności Doktoranta. Stąd luźnego powiązania tematycznego wyników nie traktuję jako rzeczy niekorzystnej w ocenie pracy.

### Ocena wkładu oryginalnego

Rozprawa jest oparta na pięciu artykułach, których współautorem jest Doktorant:

- [P1] Łukasz Lepak, Paweł Wawrzyński: *Reinforcement learning meets microeconomics: Learning to designate price-dependent supply and demand for automated trading*. European Conference on Machine Learning and Principles and Practice of Knowledge Discovery in Databases (ECML PKDD) 2024 [Punkty MNiSW: 140]
- [P2] Łukasz Lepak, Kacper Radzikowski, Robert Nowak, Karol J. Piczak: *Generalisation gap of keyword spotters in a cross-speaker low-resource scenario*. Sensors, MDPI, 2021 [Punkty MNiSW: 100]
- [P3] Paweł Wawrzyński, Paweł Zawistowski, Łukasz Lepak: *Automatic hyperparameter tuning in on-line learning: Classic Momentum and ADAM*. International Joint Conference on Neural Networks (IJCNN), IEEE, 2020 [Punkty MNiSW: 140]
- [P4] Grzegorz Rypeś, Łukasz Lepak, Paweł Wawrzyński: *Reinforcement Learning for on-line Sequence Transformation*. 17th Conference on Computer Science and Intelligence Systems (FedCSIS), IEEE, 2022 [Punkty MNiSW: 70]
- [P5] Łukasz Neumann, Łukasz Lepak, Paweł Wawrzyński: *Least Redundant Gated Recurrent Neural Network*. International Joint Conference on Neural Networks (IJCNN), IEEE, 2023 [Punkty MNiSW: 140]

Wszystkie prace zostały opublikowane w punktowanych materiałach konferencyjnych lub czasopismach. W szczególności, robią wrażenie trzy prace na prestiżowych konferencjach uczenia maszynowego: ECML PKDD oraz IJCNN (wszystkie po 140 punkty MNiSW) – jak wiemy, większość kluczowych wyników w uczeniu maszynowym publikowana jest właśnie na głównych konferencjach dziedziny, stąd aktywny w nich udział traktuję zawsze bardzo pozytywnie. Sumaryczne 590 punktów jest wynikiem bardzo dobrym jak na dorobek w trakcie doktoratu. Nie będę odnosił się tutaj do współczynnika *Impact Factor*, ponieważ materiały konferencyjne najprawdopodobniej go nie posiadają. Wkład w każdą z prac został przez Doktoranta precyzyjnie

określony i we wszystkich pracach z wyjątkiem ostatniej przewyższa średni wkład przypadający na pojedynczego współautora. Jedynym mankamentem jest dla mnie niewielka liczba cytowań (13 wg. *Google Scholar*, odczytane na przełomie styczeń/luty 2025), co jest dość zaskakujące z uwagi na bardzo dobre wyniki eksperymentalne zaproponowanych przez Doktoranta metod. Nie zmienia to jednak mojej pozytywnej opinii o całości dorobku naukowego.

Rozprawa zawiera szereg oryginalnych i nowatorskich wyników, które zostały już pozytywnie zweryfikowane w procesie recenzyjnym na etapie przyjmowania prac na konferencje i do czasopism:

- W pracy [P1] opracowano strategię składania ofert kupna i sprzedaży energii elektrycznej na rynku dnia następnego. Strategia oparta jest na metodzie uczenia ze wzmocnieniem. Tradycyjne podejścia do tego typu problemu opierały się na prostych strategiach parametrycznych, optymalizacji liniowej, lub metodach uczenia się proponujących jedynie jedną parę ofert kupna i sprzedaży w ciągu całego dnia (prowadzących do bardzo elementarnych krzywych popytu i podaży). Autorzy pracy zaproponowali strategię, w której generowane są kolekcje ofert kupna i sprzedaży energii dla każdej godziny z osobna, oparte na parametryzacji ogólnych krzywych popytu i podaży za pomocą 100-wymiarowej przestrzeni akcji agenta.

Eksperymenty przeprowadzone na symulacji polskiego rynku energii pokazały, że proponowana strategia osiąga znacznie wyższe zyski niż metody „klasyczne” bądź wcześniejsze metody oparte na uczeniu ze wzmocnieniem, nawet przy uwzględnieniu ograniczeń związanych z magazynowaniem energii i zmiennością podaży z odnawialnych źródeł. Istotnym aspektem tej pracy jest możliwość jej praktycznego zastosowania, co zostało potwierdzone zainteresowaniem ze strony przemysłu energetycznego.

- W artykule [P2] opracowany został system do wykrywania słów kluczowych w nagraniach rozmów telefonicznych w języku polskim. Ze względu na ograniczoną dostępność danych dla języka polskiego, zadanie to stanowiło duże wyzwanie badawcze. Autorzy zastosowali metody dopasowywania nagrań oparte na metryce podobieństwa, używając do tego różnych narzędzi: sieci syjamskich, sieci opartych na prototypach, oraz wektorach zanurzeń pochodzących z pre-trenowanego modelu firmy Google, z dodatkowym przetwarzaniem wyników.

Największym wyzwaniem była praca z ograniczoną liczbą danych w języku polskim i konieczność posiłkowania się danymi w języku angielskim. Na uwagę zasługuje wysiłek autorów w pozyskaniu licznych zbiorów danych, w tym samodzielnym utworzeniu znacznej części danych w języku polskim. Pomimo tych trudności autorowi udało się stworzyć system, który osiągnął dość przyzwoite wyniki detekcji słów kluczowych, w najlepszym wypadku uzyskując wynik miary  $F$  na poziomie 0.69.

- W pracy [P3] zaproponowano algorytm *Autonomous Stochastic Descent with Momentum 2 (ASDM2)*, który automatycznie dostosowuje hiperparametry metod używających członu *momentum* (takich jak CM lub Adam) podczas procesu uczenia sieci neuronowych. Jest to więc rozwinięcie istniejących metod optymalizacji sieci, wyposażające je w mechanizm,

który zamiast odgórnego określania hiperparametrów pod problem (zwykle metodą prób i błędów) pozwala na swobodną ewolucję ich wartości podczas procesu uczenia celem przyspieszenia minimalizacji błędu na zbiorze uczącym. Sposób adaptacji hiperparametrów to błyskotliwa metoda „spadku wzdłuż gradientu wewnątrz metody spadku wzdłuż gradientu”, opierająca się na wygładzaniu wykładniczym parametrów modelu i propagacji wpływu, jaki mają na nie hiperparametry (tzn. pochodnych), wykorzystując do tego odpowiednie rekurencje.

Wyniki eksperymentów przeprowadzonych na różnych architekturach sieci neuronowych, w tym płytkich sieci gęstych (dla danych tabelarycznych), gęstych, głębokich autoenkoderach i autoenkoderach konwolucyjnych, potwierdziły skuteczność proponowanego algorytmu: ASDM2 osiągnął lepsze wyniki niż popularne algorytmy uczenia w ogromnej większości przypadków, w szczególności przebił algorytm Adam z *optymalnie* strojonymi parametrami! Czyni go to obiecującym narzędziem do zastosowań w praktycznych problemach uczenia głębokiego.

- W pracy [P4] zaproponowano system *Reinforcement Learning for on-line Sequence Transformation (RLST)*, który automatycznie kontroluje opóźnienie tłumaczenia symultanicznego przy zachowaniu wysokiej jakości, używając metod uczenia ze wzmocnieniem – agent dokonuje nie tylko wyboru tokenu sekwencji wyjściowej, ale przede wszystkim wybiera jedną z dwóch akcji: odczytanie tokenu na wyjściu bądź generację tokenu wyjściowego, co pozwala na kontrolę przetargu między opóźnieniem, a jakością tłumaczenia. W przeciwieństwie do tradycyjnych metod tłumaczenia maszynowego, RLST pozwala na generowanie tłumaczeń w czasie rzeczywistym. Eksperymenty obliczeniowego na rzeczywistych danych pokazały, że RLST osiąga wyniki porównywalne z nowoczesnymi architekturami tłumaczenia maszynowego, szczególnie dla dłuższych sekwencji, gdzie utrzymanie kontekstu jest kluczowe dla wysokiej jakości tłumaczeń.
- W pracy [P5] opracowano nową komórkę rekurencyjną nazwaną *Deep Memory Update (DMU)*. Głównym celem tego rozwiązania było umożliwienie głębokiej transformacji stanu przy jednoczesnym uniknięciu problemów związanych z propagacją gradientu. W szczególności, autorzy zaproponowali użycie sieci neuronowej *feed-forward* jako nauczalnej transformacji stanu, wyposażonej w odpowiednio dobrane funkcje aktywacji. Z jednej strony transformacja taka jest uniwersalnym aproksymatorem, z drugiej strony – używając odpowiedniej struktury sieci można zapewnić (co autorzy udowodniają), że sieć taka nie prowadzi do eksplozji lub zanikania gradientów. Dodatkowo, zaproponowano odpowiedni dobór szybkości uczenia takiej transformacji celem utrzymania stabilności procesu trenowania całościowej sieci.

Eksperymenty wykazały, że DMU osiąga wyniki porównywalne, a często lepsze niż popularne sieci rekurencyjne, takie jak LSTM, GRU czy RHN. Proponowana komórka rekurencyjna ma więc potencjał do szerokiego zastosowania w zadaniach przetwarzania sekwencyjnego.

Uważam, że każda z wymienionych publikacji daje istotny wkład do dziedziny uczenia maszynowego i uznaję stąd, że wymienione na wstępie cele badawcze udało się Doktorantowi w

pełni osiągnąć.

## Uwagi dyskusyjne

Nie kwestionując wartości całościowych wyników zawartych w rozprawie, chciałbym zgłosić poniżej kilka uwag, głównie w formie pytań bądź dyskusji.

- W pracy [P1] pojawia się kilka niejasnych dla mnie elementów. Po pierwsze, do czego potrzebna jest randomizacja strategii w równaniu (10)? Oczywiście, losowe zachowanie strategii w procesie uczenia (np.  $\epsilon$ -greedy) jest kluczowe dla eksploracji, natomiast – o ile nie zakładamy wpływu strategii na rynek energii – losowość nie wydaje się potrzebna na etapie stosowania strategii na rynku energii. Po drugie, czy parametryzacja zbioru ofert kupna/sprzedaży przez akcje  $a$  jest wystarczająco elastyczna do modelowania ogólnych krzywych popytu i podaży zgodnie z dyskusją pod Rysunkiem 1? Innymi słowy: czy można pomocą równań 4-7 utworzyć dowolną kolekcję ofert kupna/sprzedaży (a jeśli nie – to jakie są ograniczenia?). Po trzecie, zastanawia mnie, do jakiego stopnia zadanie to jest problemem uczenia ze wzmocnieniem, a nie problemem uczenie nadzorowanego (ze złożonym wyjściem)? Kluczową trudnością w uczeniu się ze wzmocnieniem jest wpływ wykonywanych akcji na stan agenta, przez co lokalnie opłacalna akcja (dająca wysoką nagrodę) może nie być opłacalna w dłuższym okresie (niewielka wartość funkcji  $Q$ ). W rozważanym problemie jedynym chyba czynnikiem propagującym się na kolejne dni, na który wpływ mają akcje agenta danego dnia (rozpatrywane całościowo, jako zespół ofert kupna i sprzedaży), jest stan baterii pod koniec dnia, czyli możliwość sprzedaży nadwyżki energii w dni kolejne. Ale z danych eksperymentalnych wynika, że pod koniec dnia bateria jest zwykle bliska rozładowaniu. Stąd być może można by problem zapisać jako problem predykcji złożonego wyjścia (akcji) ocenianego przez złożoną funkcję nagrody będącą całkowitym zyskiem w ciągu dnia?
- Również odnośnie pracy [P1]: kluczowymi dla określenia zysku jest produkcja i zużycie energii przez agenta. Wartości te mogą być – zgodnie z przyjętym modelem – wyznaczone w oparciu o pogodę. Czy Autor rozważał dostarczenie agentowi na wejściu prognoz produkcji i zużycia energii w ciągu dnia wyznaczonych na podstawie prognoz pogody?
- W pracy [P2] wspomniano, że z powodu potencjalnych problemów zrezygnowano z użycia metod rozpoznawania mowy (*speech-to-text*). Czy Doktorant próbował użyć takich metod do rozwiązania problemu i porównywał je z zaproponowanymi metodami opartymi na podobnych wzorcach?
- W pracy [P3] zaproponowany algorytm cechuje się znakomitą jakością mierzoną zdolnością minimalizacji błędu uczącego, bijąc nawet (prawie) optymalnie dostrojoną metodę Adam. Autorzy pracy nie wspominają natomiast o wartości błędu na zbiorze testowym, która nie zawsze musi być dobrze skorelowana z błędem treningowym, a także nie podają czasów obliczeń algorytmu ASDM2 względem algorytmów bazowych. Byłby wdzięczny za komentarz, z ewentualnym przybliżonym podaniem tych – w praktyce bardzo istotnych – wartości, jeśli były w eksperymentach mierzone.

## **Konkluzja końcowa**

Recenzowaną rozprawę oceniam bardzo dobrze. Załączone prace potwierdzają wiedzę Doktora w zakresie uczenia maszynowego i sztucznej inteligencji, w szczególności zastosowania ich do automatyzacji zadań, oraz umiejętność prowadzenia prac badawczych. Problemy, z którymi zmierzył się mgr inż. Łukasz Lepak, są ambitne i istotne dla postępu w dziedzinie. Wyniki eksperymentów obliczeniowych na rzeczywistych danych, zawarte w rozprawie, potwierdzają wysoką jakość zaproponowanych rozwiązań. Stwierdzam, że *przedstawiona do oceny Rozprawa Doktorska spełnia warunki określone w Art. 187 Ustawy z dnia 20 lipca 2018 r./Prawo o szkolnictwie wyższym i nauce / (Dz.U. z 2022 r. poz. 574 z późn. zm.), oraz uzasadnia nadanie stopnia naukowego doktora w dyscyplinie informatyka.*

W związku z tym **rozprawę oceniam jako spełniającą wymogi stawiane pracom doktorskim i wnoszę o dopuszczenie mgr. inż. Łukasza Lepaka do dalszych etapów postępowania w sprawie nadania stopnia doktora, równocześnie sugerując wyróżnienie pracy.**

Dr hab. inż. Wojciech Kotłowski