

Częstochowa, 10.11.2023

dr hab. inż. Jarosław Bilski, prof PCz
Politechnika Częstochowska
Katedra Inteligentnych Systemów Informatycznych
ul. Armii Krajowej 36
42 – 200 Częstochowa
e-mail: jaroslaw.bilski@pcz.pl

**Recenzja rozprawy doktorskiej
mgr inż. Łukasza Neumanna
zatytułowanej:**

**Training Instabilities in Neural Network-based Sequential
Data Modelling**

Niniejsza opinia została przygotowana na prośbę Dziekana Wydziału Elektroniki i Technik Informatycznych Politechniki Warszawskiej prof. dra hab. inż. Michała Malinowskiego oraz Przewodniczącego Rady Naukowej Dyscypliny Informatyka Techniczna i Telekomunikacja dra hab. inż. Jarosława Arabasa prof. uczelni., z dnia 1 sierpnia 2023 roku. Promotorem pracy jest dr hab. inż. Robert Nowak prof. uczelni.

1. Problem badawczy i jego znaczenie

Problematyka przedstawiona w przesłanej do recenzji rozprawie doktorskiej mieści się w zakresie dyscypliny naukowej Informatyka techniczna i telekomunikacja. Tematyka rozprawy ma zdecydowanie charakter naukowy i współgra z innymi pracami badawczym podejmowanymi aktualnie zarówno w ośrodkach krajowych, jak i zagranicznych. Badany w pracy problem niestabilności podczas procesu uczenia (optymalizacji) sieci neuronowych w sekwencyjnym modelowaniu danych jest zagadnieniem złożonym i zależnym od wielu różnych czynników. Autor bada możliwość rozwiązania postawionego problemu na dwa sposoby: pierwszy polega na zastosowaniu opracowanych w tym celu wyspecjalizowanych architektur sieci

neuronowych, drugi na użyciu algorytmów drugiego rzędu. Autor w rozprawie zaproponował wykorzystanie różnych rodzajów sztucznych sieci neuronowych zarówno jednokierunkowych, konwolucyjnych, jak i rekurencyjnych. Przeprowadził również szereg badań dla różnych problemów syntetycznych i rzeczywistych. Na szczególną uwagę zasługuje opracowany system rozpoznawania reakcji alergicznych skóry, który pokazuje praktyczne zastosowanie prac autora. Bez wątplenia zaproponowana problematyka badawcza rozprawy ma duże znaczenie dla badania nowych architektur sieci neuronowych i algorytmów ich uczenia oraz pokazuje możliwości ich stosowania w rozwiązywaniu rzeczywistych problemów.

2. Zawartość rozprawy doktorskiej

Przedstawiona do recenzji rozprawa doktorska pod tytułem: *Training Instabilities in Neural Network-based Sequential Data Modelling (Niestabilności w procesie uczenia sieci neuronowych przy modelowaniu danych sekwencyjnych)* obejmuje w sumie 86 stron i oprócz wstępu, streszczenia w językach angielskim i polskim składa się z 4 rozdziałów podstawowych, zebranych osiągnięć naukowych autora, spisu literatury obejmującego ponad 100 pozycji i dwóch dodatków. W dodatku drugim umieszczone zostały trzy publikacje, na których bazuje praca. Rozprawa napisana jest w języku angielskim i składa się z następujących rozdziałów:

Rozdział 1. **Introduction (Wstęp)** - przedstawia pojęcie zbioru sekwencyjnego oraz podaje szereg przykładów takich zbiorów, problemy jakie występują przy ich przetwarzaniu, a także różne podejścia do modelowania danych sekwencyjnych. Następnie autor wskazuje wkład wnoszony w publikacjach będących podstawą pracy:

- wprowadzenie nowatorskiej architektury rekurencyjnej sieci neuronowej rozwiązującej problem eksplozji i zanikania gradientu przy jednoczesnym zmniejszeniu liczby parametrów w porównaniu z innymi sieciami;
- opracowanie opartej na metaheurystyce nowej metody uczenia sieci neuronowych;
- przedstawienie sposobu poprawy wydajności modelu w zadaniu klasyfikacji danych medycznych oraz zaproponowanie zautomatyzowanego podejścia do rozpoznawania reakcji alergicznych skóry.

Doktorant podaje tu również listę trzech publikacji (w czasopiśmie i na dwóch konferencjach), które są podstawą recenzowanej pracy (wszystkie zgodnie z listą ministerialną uzyskały po 140 punktów) oraz określa własny wkład w ich opracowanie (70%, 70% i 33,3%).

Rozdział 2. **Background (Kontekst pracy)** – składa się z trzech podrozdziałów. Pierwszy z nich opisuje metody uczenia (treningu) sieci neuronowych. Podanych jest wiele powszechnie stosowanych (w tym nowych) algorytmów pierwszego i drugiego rzędu oraz algorytmy uczenia ewolucyjnego. Podrozdział drugi zawiera zwięzły opis architektur sieci neuronowych stosowanych do modelowania danych sekwencyjnych. Do podstawowych należą: sieci rekurencyjne (RNN), sieci LSTM (Long Short-Term Memory), GRU (Gated Recurrent Unit), ich modyfikacje i inne. Podrozdział trzeci zawiera informacje nt. metod diagnostyki alergicznych reakcji skórnych, możliwości zastosowania termografii oraz automatyzacji procesu rozpoznawania reakcji alergicznych.

Rozdział 3. **Mitigating stability problems using custom neural architectures (Łagodzenie problemów ze stabilnością przy użyciu dedykowanych architektur neuronowych)** – odnosi się do publikacji oznaczonych jako P1 i P2. W pracy P1 pokazano zautomatyzowane podejście do rozpoznawania alergicznych reakcji skórnych w oparciu o sieci neuronowe. Przedstawiono procedurę postępowania oraz przeprowadzono badania kliniczne. W artykule P2 przedstawiono nową architekturę sieci rekurencyjnej opartej o komórkę DMU (Deep Memory Update), a wywodzącą się z sieci GRU. Dalej proponuje się metodę inicjalizacji otrzymanej sieci neuronowej, aby poprawić jej stabilność i skrócić czas uczenia.

Rozdział 4. **Novel Evolution Strategy-based neural network optimizer (Nowy optymalizator sieci neuronowej oparty na strategii ewolucji)** – oparty jest na pracy P3 i zawiera algorytm drugiego rzędu nazwany neural Differential Evolution Strategy (nDES). Tworzona jest populacja sieci, która podlega ewolucji. Przeprowadzono badania dla kilku problemów testowych.

Rozdział 5. **Discussion and final remarks (Dyskusja i uwagi końcowe)** – podsumowuje wnioski otrzymane w prezentowanych pracach. Przedstawia najważniejsze oryginalne osiągnięcia. Na końcu wskazuje kilka możliwości dalszego rozwijania przedstawionych rozwiązań w formie pytań.

3. Ocena pracy

Oceniana rozprawa doktorska jest w rzeczywistości połączeniem trzech opublikowanych wcześniej artykułów (podane tylko tytuły):

P1: Thermography based skin allergic reaction recognition by convolutional neural networks

P2: Least Redundant Gated Recurrent Neural Network

P3: Deep Neuroevolution: Training Neural Networks Using a Matrix-Free Evolution Strategy

W tym kontekście ocena pracy musi się do nich odnieść. Artykuł P1 przedstawia bardzo ciekawy przykład zastosowania sieci neuronowych do rozpoznawania alergicznych reakcji skórnych. Pokazano zautomatyzowane podejście do w oparciu o sieci neuronowe. Przedstawiono całościową procedurę postępowania oraz przeprowadzono badania kliniczne na rzeczywistych danych stu pacjentów. W badaniach zastosowano dwa rodzaje obrazów: w paśmie widzialnym i podczerwonym (obrazy termograficzne) przed i po iniekcji. Uzyskane obrazy podlegają segmentacji, korelacji i klasyfikacji przez konwolucyjną sieć neuronową. Do uczenia sieci zastosowano algorytm ADAM. Najważniejsze uzyskane osiągnięcia to:

- Udane zastosowanie dedykowanej architektury sieci CNN przewyższające inne rozwiązania.
- Zastosowanie różnicowych obrazów termograficznych zwiększające skuteczność rozpoznawania odczynów alergicznych skóry.
- Zbudowanie automatycznego systemu do rozpoznawania odczynów alergicznych skóry.

W artykule P2 doktorant wprowadza nową rekurencyjną architekturę neuronową o nazwie DMU (Deep Memory Update) Będącą udanym uproszczeniem architektury GRU (Gated Recurrent Units) i LSTM (Long Short-Term Memory). Jako algorytmów uczących użyto SGD i ADAM. Przeprowadzono szereg eksperymentów dla syntetycznych i rzeczywistych przykładów i porównano otrzymane wyniki z innymi architekturami uzyskując w większości lepsze rezultaty. Należy podkreślić, że:

- Zaproponowana rekurencyjna architektura DMU umożliwia dowolną transformację stanu pamięci.
- DMU jest często wydajniejsza niż inne sieci RNN.
- DMU posiada mniej parametrów wymagających uczenia niż sieci LSTM, GRU i inne.

Artykuł P3 zawiera rozwiązanie ewolucyjne nazwane nDES (neural Differential Evolution Strategy) i wywodzące się z algorytmu DES (opartego na połączeniu DE i CMA-ES(Covariance Matrix Adaptation Evolution Strategy)). W opisanym metodzie użyto inicjalizacji Xavier'a i mutacji opartej o gradient. Dodatkowo opracowano warianty zaproponowanego algorytmu. Pomyślnie przeprowadzono badania kilku

problemów testowych z wykorzystaniem opracowanych metod i algorytmu ADAM. W artykule uzyskano następujące rezultaty:

- Opracowano nowy algorytm ewolucyjnego uczenia sieci neuronowych nDES w trzech wariantach.
- Uzyskano wysoką skuteczność opracowanego algorytmu również dla architektur RNN (często lepszą od algorytmu ADAM).

Bardzo pozytywnie należy również ocenić inną działalność naukową doktoranta. We współpracy z promotorem pracy i innymi autorami opublikował szereg prac związanych z sieciami neuronowymi. Publikował również w ramach ALICE Collaboration.

Dodatkowo doktorant uczestniczył w wielu projektach badawczych. Był również kierownikiem jednego z nich.

4. Inne uwagi

Do recenzowanej pracy można przedstawić kilka uwag i komentarzy o charakterze dyskusyjnym:

- Praca jest napisana w konwencji rozszerzony wstęp/streszczenie plus trzy publikacje. Spójny, ciągły wywód bardziej pasuje do tego typu publikacji.
- W pracy doktorant nie sformułował tezy. W jej miejscu umieścić wkład/osiągnięcia pracy.
- Rozdział drugi Background zawiera szeroki przegląd metod uczenia i architektur sieci neuronowych. Niestety opis jest skrótowy. W większości przypadków brakuje podstawowych wzorów, żeby nie wspomnieć o wyprowadzeniu choćby wybranych najważniejszych algorytmów.
- Rozdziały 3 i 4 są nadmiernym streszczeniem załączonych publikacji. W rozdziałach tych można było np. przedstawić pełne wyprowadzenie opracowanych algorytmów uczenia.
- W kontekście publikacji P1 brakuje prezentacji systemu utrzymującego ramię pacjenta w zalecanej pozycji.
- Generalnie w pracy nie ma informacji o szybkości uczenia przy użyciu badanych algorytmów (z jednym wyjątkiem) w porównaniu z innymi metodami.
- Doktorant wspomina o możliwości prostego zrównoleglenia opracowanych algorytmów, należy jednak pamiętać, że większość metod uczenia sieci neuronowych można zrównoleglić i w rezultacie będzie liczyć się stosunek wydajności tych metod.

- Występują drobne błędy językowe i niejasne sformułowania.

Wymienione powyżej uwagi i niedoskonałości nie wpływają na pozytywną ocenę merytoryczną recenzowanej pracy doktorskiej.

Należy również zauważyć, że autor w rozdziale 5. pracy wskazuje kierunki dalszych badań, co pozwala oczekiwać na kolejne jego rozwiązania i publikacje.

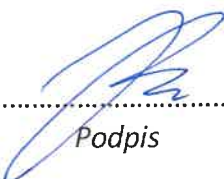
5. Wiedza kandydata

Autor rozprawy posiada niewątpliwie rozległą wiedzę w zakresie uczenia maszynowego, metod optymalizacji oraz badanego szczegółowego problemu rozpoznawania reakcji alergicznych skóry, którą przedstawia w kolejnych rozdziałach rozprawy. Wiedza ta jest właściwie stosowana przy wprowadzaniu nowych architektur sieci neuronowych, opracowywaniu algorytmu uczenia i przeprowadzaniu wielu badań dla różnych typów sieci neuronowych i problemów badawczych.

Podana przez autora bibliografia (ponad 100 pozycji) uwzględnia aktualny stan literatury światowej, cytowane są również nowe prace w tym zakresie.

6. Konkluzja

W konkluzji stwierdzam, że praca doktorska „*Training Instabilities in Neural Network-based Sequential Data Modelling*”, przedstawiona przez mgr inż. Łukasza Neumanna, **spełnia wymagania stosownej ustawy o stopniach naukowych i tytule naukowym**. Wnoszę o jej przyjęcie i dopuszczenie do publicznej obrony.



.....
Podpis