

dr hab. Małgorzata Przybyła-Kasperek, prof. UŚ
Instytut Informatyki
Wydział Nauk Ścisłych i Technicznych
Uniwersytet Śląski w Katowicach
ul. Będzińska 39, 41-205 Sosnowiec

Katowice, 21.08.2026r.

**Recenzja rozprawy doktorskiej mgr. inż. Jarosława Szkoły
pt. „Uczenie federacyjne z uwzględnieniem niepewności danych:
zaawansowane metody agregacji oparte na przedziałowych
zbiorach rozmytych”**

Niniejsza recenzja jest sporządzona w odpowiedzi na pismo Przewodniczącego Rady Dyscyplin: Nauki fizyczne, Matematyka, Informatyka techniczna i telekomunikacja, Inżynieria materiałowa na Wydziale Nauk Ścisłych i Technicznych Uniwersytetu Rzeszowskiego, dra hab. Andrzeja Wala, prof. UR z dnia 10 lipca 2026 r.

1. Problematyka badawcza pracy i jej znaczenie

Tematyka rozprawy doktorskiej wpisuje się w obszar uczenia federacyjnego (Federated Learning), metod przetwarzania danych niepewnych oraz systemów wspomagania decyzji wykorzystujących teorię przedziałowych zbiorów rozmytych (Interval-Valued Fuzzy Sets, IVFS). Praca koncentruje się na zagadnieniach związanych z budową modeli uczenia maszynowego w środowiskach rozproszonych, w których dane nie mogą być centralizowane ze względu na ograniczenia prawne, organizacyjne lub związane z ochroną prywatności. Szczególną uwagę Autor poświęca problemowi niekompletności danych, niepewności pomiarów oraz heterogeniczności rozkładów danych pomiędzy uczestnikami procesu uczenia federacyjnego.

Zasadniczym problemem badawczym podejmowanym w rozprawie jest opracowanie metod pozwalających na efektywne wykorzystanie danych niepewnych i rozproszonych przy jednoczesnym zachowaniu prywatności użytkowników. Klasyczne metody uczenia maszynowego zakładają centralizację danych i najczęściej operują na precyzyjnie określonych wartościach liczbowych, podczas gdy w wielu zastosowaniach praktycznych, zwłaszcza medycznych, dane są obarczone niepewnością, brakami oraz błędami pomiarowymi. Autor podejmuje próbę rozwiązania tego problemu poprzez integrację metod uczenia federacyjnego z teorią przedziałowych zbiorów rozmytych oraz wykorzystanie zaawansowanych operatorów agregacji informacji, takich jak całki Sugeno i Choqueta.

Istotnym elementem rozprawy jest również rozwój modeli regresji logistycznej wykorzystujących parametry przedziałowe, które mają umożliwiać zachowanie informacji o

niepewności. Rozwiązania te są następnie przenoszone do środowiska uczenia federacyjnego, gdzie niepewność lokalnych modeli jest dodatkowo uwzględniana podczas agregacji wiedzy pochodzącej od różnych klientów.

Problematyka podjęta przez Autora posiada wyraźny wymiar aplikacyjny. Zaproponowane rozwiązania zostały zweryfikowane m.in. na danych medycznych związanych z diagnostyką raka piersi oraz w systemach detekcji upadków osób starszych. Są to obszary, w których jednocześnie zapewnienie wysokiej jakości predykcji, interpretowalności modeli oraz ochrony prywatności danych ma szczególne znaczenie praktyczne.

W mojej ocenie podjęcie tej tematyki jest uzasadnione i aktualne. Rozprawa dotyczy problemów znajdujących się w głównym nurcie współczesnych badań nad sztuczną inteligencją, a zaproponowane przez Autora połączenie uczenia federacyjnego z teorią przedziałowych zbiorów rozmytych stanowi interesującą próbę rozwiązania problemu modelowania i propagacji niepewności w środowiskach rozproszonego uczenia maszynowego.

2. Cel pracy i teza badawcza

Rozprawa ma charakter cyklu spójnych tematycznie publikacji naukowych. Poszczególne prace koncentrują się wokół problemu badawczego, którym jest opracowanie metod uczenia federacyjnego zdolnych do efektywnego przetwarzania danych niepewnych, niekompletnych i rozproszonych z wykorzystaniem teorii przedziałowych zbiorów rozmytych oraz zaawansowanych mechanizmów agregacji modeli.

Głównym celem naukowym cyklu jest opracowanie nowych metod modelowania niepewności oraz agregacji wiedzy w środowisku uczenia federacyjnego, pozwalających na poprawę jakości modeli budowanych na danych heterogenicznych, nieźrównoważonych i obarczonych brakami danych. Cel ten został realizowany poprzez rozwój kolejnych elementów podejścia, obejmujących m.in. reprezentację danych niepewnych za pomocą przedziałowych zbiorów rozmytych, opracowanie metod uczenia dla danych niekompletnych i nieźrównoważonych, modyfikację procedur aktualizacji parametrów modeli lokalnych, konstrukcję modeli regresji logistycznej z wagami przedziałowymi oraz opracowanie nowych metod agregacji modeli federacyjnych opartych na całkach Sugeno i Choqueta oraz miarach entropii.

Cele badawcze są konsekwentnie realizowane w kolejnych publikacjach tworzących rozprawę. Poszczególne prace rozwijają kolejne elementy proponowanego podejścia, począwszy od problemu braków danych i określania wag klientów w środowisku federacyjnym, poprzez rozwój metod agregacji, aż do konstrukcji modeli wykorzystujących parametry przedziałowe i mechanizm entropii. Dzięki temu cały cykl tworzy logiczną i dobrze powiązaną ścieżkę badawczą.

3. Poprawność i struktura pracy

Podstawę rozprawy stanowi dziewięć publikacji naukowych opublikowanych w latach 2022-2026 w czasopiśmie oraz materiałach konferencyjnych o zasięgu międzynarodowym. Zasadniczą część rozprawy stanowią załączone publikacje naukowe dokumentujące kolejne etapy prowadzonych badań. Oprócz cyklu publikacji Autor przygotował komentarz autorski obejmujący streszczenie, wykaz publikacji, wprowadzenie i motywację badań, opis własnego wkładu naukowego oraz omówienie prac badawczych. Część końcową rozprawy stanowi synteza uzyskanych wyników wraz z przedstawieniem potencjalnych kierunków dalszych badań.

We wprowadzeniu Autor przedstawia problematykę badawczą oraz uzasadnia potrzebę prowadzenia badań. Następnie omawia własny wkład naukowy oraz syntetycznie charakteryzuje publikacje wchodzące w skład rozprawy. W kolejnych częściach omówiono wyniki badań prezentowane w poszczególnych publikacjach. Początkowe prace dotyczą problemu niekompletności danych oraz możliwości wykorzystania przedziałowych zbiorów rozmytych w procesie uczenia federacyjnego. Następnie Autor analizuje zagadnienia związane z agregacją modeli lokalnych i przydzielaniem wag klientom biorącym udział w uczeniu federacyjnym. Ostatnie publikacje koncentrują się na modelach wykorzystujących parametry przedziałowe (w szczególności regresji logistycznej) oraz na mechanizmach agregacji uwzględniających poziom niepewności modeli lokalnych. Rozprawę zamyka podsumowanie najważniejszych osiągnięć badawczych oraz dyskusja możliwych kierunków dalszego rozwoju proponowanych metod.

Podsumowując, struktura rozprawy jest przejrzysta i odpowiada wymaganiom stawianym rozprawom doktorskim przygotowanym w formie cyklu publikacji. Przedstawiony materiał tworzy logiczną i uporządkowaną całość, umożliwiając ocenę zarówno rozwoju prowadzonych badań, jak i wkładu Autora w rozwój omawianej problematyki.

4. Najważniejsze wyniki naukowe

Na podstawie analizy przedłożonej rozprawy oraz publikacji wyróżniam pięć najistotniejszych wyników naukowych. Ze względu na współautorski charakter wszystkich publikacji przedstawiona poniżej ocena odnosi się przede wszystkim do tych rezultatów, które w komentarzu autorskim zostały wskazane jako elementy indywidualnego wkładu Doktoranta.

Pierwszym wynikiem jest opracowanie i rozwój procedur uczenia modeli lokalnych na danych przedziałowych, niekompletnych i obciążonych niepewnością. W początkowych pracach cyklu Doktorant współtworzył metodę, w której dane wejściowe mają postać przedziałów, natomiast parametry regresji logistycznej pozostają skalarne. Początkowo wartości przedziałowe sprowadzano do reprezentantów, co pozwalało stosować klasyczną optymalizację gradientową. W kolejnych badaniach zastąpiono ją procedurą aktualizacji parametrów opartą na miarach podobieństwa przedziałowego. Pozwoliło to uzyskać większą stabilność modelu przy rosnącym udziale brakujących wartości. W kolejnych pracach zastosowano operacje na przedziałach, umożliwiające propagowanie informacji o niepewności

nie tylko na poziomie danych wejściowych, lecz także na poziomie parametrów i wyniku modelu. Istotną wartością tego osiągnięcia jest stopniowe rozwinięcie sposobu uczenia, od wyboru reprezentanta przedziału, przez aktualizację parametrów opartą na podobieństwie, aż do bezpośredniego wykorzystania arytmetyki przedziałowej.

Drugim osiągnięciem jest opracowanie mechanizmów agregacji modeli lokalnych z wykorzystaniem całek Sugeno i Choqueta. W proponowanym podejściu waga klienta jest wyznaczana na podstawie jakości uzyskanego modelu, mierzoną m.in. za pomocą dokładności lub pola pod krzywą ROC. Na tej podstawie konstruowana jest miara rozmyta, wykorzystywana następnie do agregacji kolejnych parametrów modeli lokalnych. Wyniki badań wskazują, że zaproponowane operatory agregacji są szczególnie użyteczne w przypadku nierównomiernego rozkładu klas pomiędzy klientami.

Trzecim wynikiem jest opracowanie regresji logistycznej z wieloprzedziałową reprezentacją wag. W zaproponowanym modelu pojedynczy współczynnik regresji zastąpiono sekwencją podprzedziałów, którym przypisano odrębne wartości reprezentujące wpływ danej cechy w określonym zakresie jej wartości. Opracowano również procedurę optymalizacji podziału, w której zbyt wąskie podprzedziały są scalane zgodnie z wartością zadanego progu. Osiągnięcie to jest istotne, ponieważ modyfikuje samą strukturę modelu, a nie jedynie sposób reprezentowania jego danych wejściowych. Ponadto rozwiązanie to pozwala różnicować wpływ poszczególnych zakresów wartości atrybutu na wynik predykcji, zamiast określać jedną wagę dla całego atrybutu.

Czwartym wynikiem jest opracowanie mechanizmu łączącego jakość predykcyjną modeli lokalnych z oceną ich niepewności. Wagi uczestników uczenia federacyjnego wyznaczone są na podstawie miary jakości modelu oraz entropii przedziałowej opisującej niepewność jego parametrów lub danych. W rezultacie większe znaczenie uzyskują modele o wysokiej jakości i względnie małej niepewności, natomiast wpływ modeli mniej wiarygodnych jest ograniczany.

Piątym osiągnięciem jest opracowanie hybrydowego systemu detekcji upadków łączącego uczenie federacyjne, przedziałowy system wnioskowania rozmytego oraz model regresyjny. Warunki reguł Takagiego-Sugeno zostały zapisane w postaci przedziałowej, co pozwoliło uwzględnić nieprecyzyjność pomiarów pochodzących z czujników i map głębi. Końcowa decyzja jest otrzymywana przez agregację wyników reguł, natomiast uczenie federacyjne umożliwia doskonalenie modeli bez przesyłania danych źródłowych. Rezultat ten pokazuje możliwość praktycznego wykorzystania proponowanych metod poza podstawowym zbiorem danych dotyczącym diagnostyki raka piersi.

Zasadnicza część badań została wykonana na zbiorze Wisconsin Diagnostic Breast Cancer Dataset, obejmującym dane dotyczące 569 przypadków diagnostycznych raka piersi. Drugi obszar zastosowań dotyczył wykrywania upadków osób starszych. W eksperymentach porównano modele scentralizowane, modele lokalne oraz różne warianty uczenia federacyjnego. Analizie poddano klasyczne uśrednianie parametrów, agregację ważoną jakością modeli lokalnych, a także metody wykorzystujące całki Sugeno i Choqueta oraz miary entropii. Głównym modelem predykcyjnym była regresja logistyczna. Badania federacyjne prowadzono początkowo dla dwóch, a następnie dla trzech klientów. Uwzględniono zarówno sytuację zbliżoną do danych IID, w której proporcje klas u poszczególnych klientów były zachowane, jak i wariant non-IID. W analizowanym scenariuszu non-IID jeden klient

dysponował zbalansowanym rozkładem klas, natomiast u dwóch pozostałych zastosowano przeciwne proporcje 70% do 30% i 30% do 70% (w pracy [P3] zastosowano podział 20% do 80% i 80% do 20%). Autor analizował również scenariusze z brakującymi wartościami, obejmujące brak całego atrybutu u jednego z klientów oraz losowe braki danych na poziomie od 10% do 50%. Skuteczność metod oceniano za pomocą kilku miar jakości klasyfikacji. Przeprowadzone eksperymenty dokumentują zachowanie proponowanych metod w kolejnych wariantach badanego problemu: przy danych kompletnych i niekompletnych, zbalansowanych i niezbalansowanych, a także przy zastosowaniu różnych procedur uczenia oraz agregacji parametrów lokalnych. Zakres badań pozwolił na porównanie kolejnych etapów rozwoju proponowanego podejścia oraz wskazanie wariantów osiągających najlepsze wyniki w przyjętych scenariuszach eksperymentalnych. Przeprowadzona weryfikacja eksperymentalna potwierdza zasadność zaproponowanych rozwiązań, a całość badań prezentuje bardzo dobry poziom, odpowiadający wymaganiom stawianym rozprawom doktorskim.

5. Uwagi i dyskusja

Zaproponowane metody stanowią interesujący i ważny wkład w rozwój uczenia federacyjnego uwzględniającego niepewność danych. Lektura rozprawy skłania jednak do sformułowania kilku uwag oraz pytań o charakterze dyskusyjnym, które warto poruszyć podczas publicznej obrony.

Pierwsza uwaga dotyczy zakresu danych wykorzystanych w eksperymentach, które przeprowadzono głównie na zbiorze Wisconsin Diagnostic Breast Cancer oraz danych dotyczących detekcji upadków. Autor wskazuje rozszerzenie badań na inne zbiory i dziedziny zastosowań jako jeden z kierunków dalszych prac. W związku z tym interesujące jest, czy podjęto już wstępne eksperymenty na innych danych i czy ich wyniki potwierdzają możliwość uogólnienia zaproponowanych metod.

W większości publikacji podstawowym modelem była regresja logistyczna. W pracy dotyczącej wykrywania upadków wykorzystano również hybrydowe rozwiązanie łączące model regresyjny z przedziałowym systemem wnioskowania Takagiego-Sugeno. Powstaje jednak pytanie o możliwość przeniesienia opracowanych mechanizmów na inne modele uczenia maszynowego, w szczególności drzewa decyzyjne, metody zespołowe, maszyny wektorów nośnych oraz sieci neuronowe. Wiemy, że niektóre elementy proponowanego podejścia mają charakter uniwersalny, a inne są ściśle związane ze strukturą regresji logistycznej – dobrze byłoby to podsumować.

Istotnym zagadnieniem jest także skalowalność proponowanych metod względem liczby klientów w uczeniu federacyjnym. Początkowe eksperymenty przeprowadzono dla dwóch klientów, natomiast w kolejnych publikacjach analizowano układ obejmujący trzech klientów. Interesujące jest, jak zachowują się proponowane metody agregacji przy kilkunastu, kilkudziesięciu lub większej liczbie klientów. Czy Doktorant prowadził już wstępne eksperymenty dla większej liczby klientów i czy zaobserwował wpływ na jakość modelu oraz stabilność procesu agregacji?

W badaniach uwzględniono scenariusze danych IID i non-IID. W zależności od publikacji stosowano zbalansowany rozkład klas u jednego klienta oraz przeciwne proporcje klas u pozostałych klientów (występowały dwa warianty 20% do 80% i 30% do 70%). Są to czytelne scenariusze umożliwiające kontrolowaną ocenę wpływu niezbalansowania danych. Problem heterogeniczności danych federacyjnych jest jednak szerszy i może obejmować również bardziej skrajne proporcje klas, brak jednej z klas u wybranych klientów oraz nierówną liczebność lokalnych zbiorów. Warto byłoby przedyskutować, czy skuteczność agregacji opartej na całce Choqueta i entropii utrzymałaby się także w takich warunkach oraz jaki poziom heterogeniczności danych może stanowić granicę użyteczności proponowanego rozwiązania.

W rozprawie nie przeprowadzono jednolitej analizy porównującej czas działania i złożoność wszystkich proponowanych wariantów. Byłoby wartościowe zestawienie kosztów klasycznej agregacji FedAvg, agregacji ważonej jakością modelu, całki Sugeno, całki Choqueta oraz wariantów uwzględniających entropię. W przypadku zastosowań uczenia federacyjnego ważny jest nie tylko czas lokalnego uczenia i agregacji, lecz także liczba rund komunikacyjnych oraz rozmiar przesyłanych parametrów. Doktorant, realizując eksperymenty, z pewnością zaobserwował różnice w kosztach obliczeniowych poszczególnych metod. Proszę o komentarz wynikający z praktyki i ocenę kosztu uzyskania lepszej jakości predykcji (jak wzrost złożoności mechanizmów uczenia i agregacji przekłada się na czas obliczeń).

Kolejna kwestia dotyczy wpływu wartości hiperparametrów na uzyskiwane wyniki. W eksperymentach przyjmowano między innymi określone wartości współczynnika uczenia α , parametru reprezentanta przedziału γ , liczby epok lokalnych i rund agregacji, a w modelu wielopredziałowym również liczby podprzedziałów z oraz progu ich scalania ψ . Zapewne Doktorant analizował różne konfiguracje tych parametrów, a w publikacjach przedstawił warianty prowadzące do najlepszych rezultatów. Interesujące byłoby zatem omówienie, jak zmiany poszczególnych parametrów wpływały na jakość i stabilność modeli, który z nich miał znaczenie decydujące, a wpływ których był stosunkowo niewielki.

Rozważane problemy klasyfikacyjne mają charakter binarny. Powstaje zatem pytanie o możliwość rozszerzenia zaproponowanej regresji logistycznej z wagami wielopredziałowymi na problemy wieloklasowe, a także o to, jakie elementy procedury uczenia i agregacji wymagałyby wówczas zmiany lub dostosowania.

Wskazane uwagi i pytania mają charakter uzupełniający. Nie podważają one zasadniczej wartości uzyskanych wyników ani pozytywnej oceny rozprawy, lecz dotyczą przede wszystkim zakresu ich uogólnienia, skalowalności oraz możliwości zastosowania proponowanych mechanizmów w bardziej złożonych i zróżnicowanych środowiskach uczenia federacyjnego.

6. Podsumowanie i wnioski końcowe

Recenzowana rozprawa doktorska mgr. inż. Jarosława Szkoły zawiera oryginalne rozwiązania problemów naukowych dotyczących uczenia federacyjnego w warunkach niepewności, niekompletności i heterogeniczności danych. Doktorant wykazał się odpowiednią wiedzą teoretyczną w zakresie uczenia maszynowego, teorii przedziałowych zbiorów

rozmytych i metod agregacji informacji, a także umiejętnością projektowania, implementowania oraz eksperymentalnego weryfikowania nowych rozwiązań algorytmicznych. Przedstawiony cykl dziewięciu publikacji jest spójny tematycznie i dokumentuje kolejne etapy rozwoju prowadzonych badań. W skład cyklu wchodzi między innymi artykuły opublikowane w czasopismach: IEEE Access, International Journal of Applied Mathematics and Computer Science oraz Journal of Artificial Intelligence and Soft Computing Research. Istotną część cyklu stanowią również publikacje prezentowane na konferencji IEEE International Conference on Fuzzy Systems, jednej z rozpoznawalnych międzynarodowych konferencji poświęconych systemom rozmytym i inteligencji obliczeniowej.

Podsumowując, stwierdzam, że recenzowana przez mnie rozprawa spełnia wymagania stawiane rozprawom doktorskim określone w art. 187 ust. 1-3 Ustawy z dnia 20 lipca 2018 r. Prawo o szkolnictwie wyższym i nauce (Dz.U. z 2018 r. poz. 1668 z późn. zm.). W związku z powyższym wnoszę o dopuszczenie mgr. inż. Jarosława Szkoły do publicznej obrony rozprawy doktorskiej.

