



Poznań, 15.09.2025 r.

dr hab. Arkadiusz Kawa, prof. UEP
Uniwersytet Ekonomiczny w Poznaniu
Instytut Gospodarki Międzynarodowej
Katedra Relacji Biznesowych i Marketingu Międzynarodowego

RECENZJA

rozprawy doktorskiej mgr inż. Fredricka Wanyamy Mumali pt. „A methodology for intelligent support in the selection of manufacturing processes based on Generalized Matrix Learning Vector Quantization neural network”, przygotowanej na Wydziale Inżynierii Zarządzania Politechniki Poznańskiej, w dziedzinie nauk społecznych w dyscyplinie nauki o zarządzaniu i jakości, pod opieką naukową promotora dr hab. inż. Joanny Kałkowskiej, prof. PP i promotora pomocniczego dra inż. Michała Trziszki

I. Podstawy formalne wykonania recenzji

Podstawą opracowania recenzji jest Uchwała nr 58/2024-2028 Rady Dyscypliny Nauk o Zarządzaniu i Jakości Politechniki Poznańskiej z dnia 30 czerwca 2025 r., na mocy której zostałem wyznaczony recenzentem rozprawy doktorskiej mgr inż. Fredricka Wanyamy Mumali. O przygotowanie recenzji zwrócił się Dziekan Wydziału Inżynierii Zarządzania Politechniki Poznańskiej, dr hab. inż. Marcin Butlewski, prof. PP, pismem z prośbą o ocenę, które wraz z rozprawą doktorską otrzymałem 23 lipca 2025 r.

Przewód doktorski prowadzony jest na podstawie ustawy z dnia 20 lipca 2018 r. – Prawo o szkolnictwie wyższym i nauce (Dz.U. 2023 poz. 742). Zgodnie z obowiązującymi przepisami rozprawa doktorska powinna stanowić oryginalne rozwiązanie problemu naukowego oraz wykazywać ogólną wiedzę teoretyczną kandydata w danej dyscyplinie lub dyscyplinach i umiejętność samodzielnego prowadzenia pracy naukowej. W związku z powyższym celem niniejszej recenzji jest ustalenie, czy rozprawa doktorska mgr inż. Fredricka Wanyamy Mumali spełnia te wymagania, a więc: czy stanowi oryginalne rozwiązanie problemu naukowego w dyscyplinie nauki o zarządzaniu i jakości oraz czy przedstawia wymaganą wiedzę teoretyczną i zdolność Doktoranta do samodzielnego prowadzenia badań naukowych.

Przedmiotem oceny jest rozprawa doktorska napisana w języku angielskim o objętości 223 stron, z czego 151 stron stanowi zasadniczy tekst. Składa się ona z tytułowej strony, streszczenia (w języku angielskim i polskim), podziękowań, wykazu skrótów, spisu treści,

wstępu, czterech rozdziałów, zakończenia, bibliografii oraz spisów ilustracji i tabel. Struktura pracy obejmuje: Wprowadzenie (z uzasadnieniem tematu, hipotezami, celami, metodyką i strukturą pracy), Rozdział 2 – Empiryczne spojrzenie na ograniczenia procesu wyboru procesu produkcyjnego (badania ankietowe i analiza wpływu czynników subiektywnych), Rozdział 3 – Inteligentne wsparcie w wyborze procesów produkcyjnych (przegląd systematyczny literatury dotyczący metod wspomagania decyzji), Rozdział 4 – Uogólniona kwantyzacja wektorów (GMLVQ) (teoretyczne podstawy algorytmu i przegląd literatury na jego temat), Rozdział 5 – Metodologia inteligentnego wsparcia wyboru procesu produkcyjnego (proponowane rozwiązanie oparte na GMLVQ, eksperymenty i wyniki) oraz Wnioski i perspektywy na przyszłość. Rozprawa zawiera ponadto liczne rysunki i tabele ilustrujące wyniki, a bibliografia obejmuje 436 źródeł, tym literaturę krajową i zagraniczną, artykuły naukowe z ostatnich lat, materiały internetowe oraz publikacje własne Doktoranta.

II. Ocena ogólna

Przedłożona do recenzji rozprawa doktorska dotyczy metod inteligentnego wspomagania decyzji w wyborze procesów wytwarzania z zastosowaniem algorytmu sieci neuronowej Generalized Matrix Learning Vector Quantization (GMLVQ). Tematyka ta jest bardzo aktualna i ważna zarówno z naukowego, jak i praktycznego punktu widzenia. W dobie rosnącej złożoności procesów produkcyjnych i roli człowieka w tych procesach (Przemysł 5.0) przedsiębiorstwa poszukują zaawansowanych narzędzi analitycznych, aby optymalizować decyzje technologiczne. Autor trafnie zauważa, że w obliczu dynamicznych potrzeb klientów, niepewności rynkowej oraz nacisku na zrównoważony rozwój, wybór właściwej technologii wytwarzania staje się kluczowy dla produktywności i konkurencyjności firm. Rozprawa wpisuje się więc w interdyscyplinarny nurt badań łączących nauki o zarządzaniu i jakości (usprawnianie procesów decyzyjnych) z technikami sztucznej inteligencji (opracowanie i zastosowanie algorytmu uczącego się).

Autor wykazał się bardzo dobrą orientacją w literaturze przedmiotu oraz znajomością zaawansowanych metod uczenia maszynowego. Na uznanie zasługuje zwłaszcza szeroki przegląd badań i źródeł, który posłużył do identyfikacji luki badawczej i uzasadnienia podjętego tematu. Doktorant podjął się próby rozwiązania zidentyfikowanego problemu badawczego poprzez opracowanie własnej metodyki i jej weryfikację eksperymentalną.

Należy jednak zaznaczyć, że rozprawa nie jest pozbawiona uchybień. Mimo że struktura pracy obejmuje wszystkie niezbędne elementy, to nie jest ona logicznie poukładana. Po wprowadzeniu znajduje się rozdział empiryczny z hipotezami, badaniem i wynikami, a po nim są dwa przeglądy literatury. Układ powinien być odwrotny, nawet jeśli przegląd literatury dotyczy innych zagadnień. To powoduje, że dość słaba jest integracja części teoretycznej z empiryczną. Strukturalnie praca dzieli się na część „społeczno-zarządczą”

oraz „inżynierską”. O ile taki podział jest naturalny przy interdyscyplinarnym temacie, o tyle zabrakło mocniejszych klamr spajających te dwie płaszczyzny. Na przykład, w ograniczonym stopniu pokazano, jak dokładnie wnioski z analizy badań ankietowych zostały wykorzystane przy budowie modelu GMLVQ. Czy czynniki decyzyjne identyfikowane przez menedżerów stały się cechami wejściowymi modelu? Czy problemy wskazywane w firmie (np. zbyt długi czas wyboru technologii) zostały rozwiązane dzięki modelowi? Tego typu powiązania nie są wyeksponowane. Również w odwrotnym kierunku, czyli interpretacja wyników modelu w kontekście zarządczym nie jest w pełni zadowalająca. Czy i jak proponowane narzędzie zmieniłoby proces decyzyjny w przedsiębiorstwie? Jakie potencjalne bariery organizacyjne mogłyby wystąpić przy wdrażaniu takiego narzędzia? Te pytania pozostają w dużej mierze poza zakresem pracy, choć należą do szerszej perspektywy zarządczej. W efekcie Czytelnik ma wrażenie, że część pierwsza (analiza problemu z punktu widzenia nauk o zarządzaniu i jakości) oraz część druga (rozwiązanie techniczne) zostały zestawione obok siebie, ale nie są w pełni połączone. Jest to o tyle ważne, że rozprawa jest oceniana w dyscyplinie nauki o zarządzaniu i jakości, więc mocniejsze zaakcentowanie implikacji zarządczych podniosłoby wartość pracy w tej dyscyplinie.

Ponadto rozdział z wynikami badań ankietowych budzi wiele wątpliwości. Dyskusyjne są pewne aspekty planu badawczego i analizy wyników. Ograniczenia dotyczą m.in. zakresu danych i walidacji wyników i aspektów zrównoważonego rozwoju. Uwagi te zostaną przedstawione szczegółowo w dalszej części recenzji.

Pomimo wskazanych zastrzeżeń, należy podkreślić, że praca stanowi oryginalne podejście do ważnego zagadnienia. Moja ocena ogólna rozprawy jest zatem pozytywna, ponieważ Autor podjął się ambitnego tematu i w znacznym stopniu osiągnął postawione cele badawcze.

III. Ocena szczegółowa

Uzasadnienie wyboru tematu

Na samym początku warto odnieść się do samego tytułu rozprawy, w którym Autor użył sformułowania „A methodology for intelligent support”. Należy zauważyć, że w literaturze naukowej termin „methodology” odnosi się do ogólnych ram i refleksji nad doбором metod badawczych, a nie do samej metody czy algorytmu. Tymczasem praca koncentruje się przede wszystkim na zaproponowaniu i przetestowaniu konkretnego rozwiązania algorytmicznego (GMLVQ) oraz jego aplikacji w procesie decyzyjnym. Nie widać tu rozbudowanej refleksji epistemologicznej ani tworzenia ram metodycznych. To raczej opracowanie nowej metody, a nie pełnej metodologii badań naukowych. W tym sensie trafniejsze i precyzyjniejsze byłoby użycie określenia „method”, „approach” lub „framework”, które lepiej oddają charakter przedstawionego rozwiązania jako procedury praktycznej, a nie metodologii badań.

Tematyka rozprawy została uzasadniona aktualnymi wyzwaniami stojącymi przed sektorem produkcyjnym. Autor wskazał, że dynamiczny rozwój technologiczny, zmienność wymagań klientów oraz dążenie do efektywności i konkurencyjności wywierają presję na przedsiębiorstwa produkcyjne. W tym kontekście kluczowe jest podejmowanie trafnych decyzji dotyczących wyboru procesu wytwórczego (np. tradycyjnej obróbki ubytkowej wobec druku 3D itp.), gdyż decyzje te rzutują na koszty, jakość i czas realizacji produktów. Autor trafnie zauważa, że inteligentne systemy wsparcia decyzji mogą odegrać istotną rolę w zbalansowaniu różnych kryteriów (wydajność, koszty, czas) i pomóc w doborze technologii.

Wybór algorytmu GMLVQ jako głównej osi proponowanej metodyki został również przekonująco uzasadniony. W literaturze przedmiotu podkreśla się zalety GMLVQ, m.in. zdolność do uczenia się istotności cech oraz radzenia sobie z danymi wysokowymiarowymi i „zaszumionymi”. Algorytm ten uznaje się za obiecujący dla złożonych problemów klasyfikacyjnych, zwłaszcza gdy istotne jest efektywne przetwarzanie danych przy ograniczonych zasobach obliczeniowych. Doktorant argumentuje, że cechy te czynią GMLVQ dobrą propozycją do zastosowania w systemie wspomagającym decyzje o wyborze procesu produkcyjnego, gdzie występuje potrzeba uwzględnienia wielu parametrów produktu i procesu.

Należy przy tym zauważyć, że w uzasadnieniu tematu wspomniano również o zrównoważonym rozwoju jako jednym z istotnych współczesnych priorytetów. Jednakże ten aspekt nie został w pracy pogłębiony. Ani w celach badawczych, ani w analizie wyników nie pojawiają się wyraźne kryteria środowiskowe czy społeczne związane z wyborem procesu. Jest to pewna luka, gdyż przy obecnych trendach można by oczekiwać uwzględnienia również takich kryteriów. Mimo to, ogólnie oceniam, że wybór tematu jest trafny (poza wspomnianym hasłem „methodology”) i dobrze umotywowany ważnymi przesłankami naukowymi oraz praktycznymi.

Sformułowanie problemu badawczego

Problematyka badawcza została sformułowana wokół pytania, jak zaprojektować inteligentne narzędzie wspomagające wybór optymalnego procesu wytwarzania dla danego wyrobu z wykorzystaniem algorytmu GMLVQ. Innymi słowy, Autor podjął problem opracowania metod, które automatycznie rekomendują technologię produkcji na podstawie zdefiniowanych parametrów (cech) produktu i warunków. Tak postawiony problem mieści się na pograniczu dwóch obszarów – zarządczego (usprawnienie procesu decyzyjnego menedżerów produkcji oraz informatycznego (zastosowanie i trening konkretnego modelu uczenia maszynowego do realizacji tego zadania).

W mojej ocenie sformułowanie problemu jest zrozumiałe i adekwatne. Autor wyraźnie identyfikuje, czego brakuje w istniejących rozwiązaniach (brak wystarczająco skutecznego systemu rekomendującego procesy technologiczne) i proponuje kierunek rozwiązania

przez implementację nowego algorytmu. Problem badawczy został przedstawiony zarówno w kategoriach teoretycznych (jako luka w wiedzy naukowej), jak i praktycznych (realna potrzeba przemysłu).

Jak już wcześniej zaznaczyłem, punkt ciężkości problemu został położony bardziej na aspekt techniczny niż zarządczy. Praca skupia się głównie na pytaniu, jak osiągnąć wysoką skuteczność rekomendacji procesu za pomocą modelu, podczas gdy mniej uwagi poświęcono pytaniu, jak takie rekomendacje zostaną włączone w proces decyzyjny firmy i mogą być zaakceptowane przez decydentów. Innymi słowy, aspekt organizacyjny (np. integracja narzędzia z praktyką zarządzania w przedsiębiorstwie) mógłby być silniej zaznaczony w definiowaniu problemu. Nie zmienia to jednak faktu, że zasadnicze rdzenie problemu badawczego zostało poprawnie sformułowane i jest on oryginalny na tle dotychczasowych badań.

Luka badawcza

Luka badawcza została w rozprawie wyraźnie zidentyfikowana. Na podstawie przeprowadzonego przeglądu literatury Doktorant wykazał, że dotychczas nie opracowano skutecznego rozwiązania wykorzystującego algorytm GMLVQ do wspomaganie wyboru procesu wytwórczego. W literaturze dominują inne podejścia, tj. logika rozmyta jest często stosowana w przypadku technologii przyrostowych (np. druk 3D), gdzie sprawdza się przy nieprecyzyjnych danych, natomiast sztuczne sieci neuronowe są wykorzystywane przy tradycyjnych procesach dzięki dostępności dużych zbiorów danych historycznych; algorytmy genetyczne służą głównie do zagadnień optymalizacyjnych. Brakuje natomiast doniesień o zastosowaniu nowszych algorytmów opartych na uczeniu relewancji cech, takich jak GMLVQ, w kontekście doboru procesu technologicznego. To właśnie tę lukę (brak zastosowań GMLVQ w problematyce wyboru procesu produkcji) praca doktorska ma wypełnić.

Podkreślić należy, że identyfikacja luki została poparta bardzo szerokim przeglądem literatury. Autor przeanalizował 93 publikacje z ostatniej dekady dotyczące inteligentnego wspomaganie decyzji w doborze procesów wytwórczych oraz 61 prac z zakresu samych algorytmów typu LVQ/GMLVQ. Zbudowanie takiej podstawy literaturowej świadczy o rzetelności badacza i pozwoliła na wiarygodne wskazanie obszarów, które nie zostały jeszcze rozwinięte. Co więcej, w toku analizy literatury Autor nie tylko wskazał braki, ale i kierunki potencjalnych rozwiązań. Z lektury pracy wynika, że dostrzegł On trend rosnącego zainteresowania algorytmami uczącymi się relewancji cech w odpowiedzi na wyzwania związane z wielowymiarowością i złożonością danych. To uzasadnia hipotezę, że przeniesienie tych algorytmów na grunt selekcji procesu produkcyjnego może przynieść wymierne korzyści.

Jedynym uzupełnieniem, jakie można zasugerować odnośnie do luki badawczej, jest uwzględnienie wspomnianego wcześniej aspektu zrównoważonego rozwoju. Przegląd literatury mógłby objąć również źródła wskazujące na brak prac łączących wybór procesu

z kryteriami zrównoważonego rozwoju (np. minimalizacja śladu środowiskowego procesu). Taka luka nie została wprost sformułowana, choć faktycznie istnieje zapotrzebowanie na narzędzia decyzyjne uwzględniające także kryteria ekologiczne i społeczne. Mimo to należy podkreślić, że główna luka naukowa identyfikowana przez Autora jest istotna i dobrze udokumentowana.

Cele pracy

Cel główny pracy został sformułowany jasno: opracowanie „metodologii” wykorzystującej zaawansowane techniki sieci neuronowych do wsparcia optymalnego podejmowania decyzji dotyczących wyboru procesu produkcyjnego. Realizacji tego celu podporządkowano cele częściowe, które z kolei podzielone zostały na zadania badawcze. Należą do nich m.in.:

- Przegląd istniejących metod wspomagania decyzji w produkcji oraz dostępnych algorytmów AI w celu zidentyfikowania luk i zdefiniowania wymagań dla nowego rozwiązania.
- Zaprojektowanie własnej „metodologii” decyzyjnego opartego na algorytmie GMLVQ, uwzględniającego specyfikę problemu (cechy produktów, kryteria wyboru procesu).
- Przeprowadzenie eksperymentów z wykorzystaniem wytrenowanego modelu w celu sprawdzenia jego skuteczności (np. dokładności decyzji) oraz przydatności; porównanie wyników z oczekiwaniami lub ewentualnie z innymi podejściami; identyfikacja ograniczeń i obszarów do usprawnienia.

Na podstawie analizy pracy można stwierdzić, że większość celów została osiągnięta przez Autora. Przede wszystkim w pełni zrealizowano cel polegający na przeglądzie literatury, co zapewniło mocne podstawy teoretyczne do dalszych prac. Na tej bazie Autor przedstawił następnie koncepcję własnego rozwiązania, m.in. określił, jakie moduły zawiera proponowane narzędzie. Model GMLVQ został zaimplementowany i przetestowany na wybranym zbiorze danych. Wreszcie, Autor zaprezentował wyniki eksperymentów. Należy więc stwierdzić, że główny cel rozprawy został osiągnięty: Doktorant przedstawił „metodologię” wspomagania decyzji z użyciem GMLVQ.

Zauważam jednak pewne niedociągnięcia w realizacji celów częściowych, zwłaszcza na etapie weryfikacji rozwiązania. Przedstawione eksperymenty mają ograniczony zakres, ponieważ skupiono się na pokazaniu, że model działa na pewnym zbiorze danych, ale brakuje szerszej walidacji. Wydaje się, że nie w pełni zrealizowano weryfikację opracowanego modelu czy zebrano dowody empiryczne potwierdzające ich skuteczność. Praca nie opisuje wdrożenia pilotażowego w rzeczywistym środowisku decyzyjnym ani konsultacji wyników z ekspertami z branży. Tego rodzaju działania mogłyby potwierdzić, że model nie tylko działa teoretycznie, ale faktycznie przynosi wartość decydentom. Ponadto, jeżeli wśród celów szczegółowych zakładano porównanie proponowanej metody z innymi, to nie zostało to uwidocznione w pracy.

Metodyka badań

Metodyka badań zastosowana w rozprawie jest zróżnicowana i obejmuje zarówno elementy jakościowe, jak i ilościowe. W pierwszej kolejności Autor przeprowadził badania empiryczne, a potem systematyczny przegląd literatury, co stanowiło bazę do kolejnej części pracy. Następnie wykorzystano analizę danych i modelowanie algorytmiczne. Głównym narzędziem ilościowym był autorski model oparty na sieci neuronowej GMLVQ, który został zaimplementowany i wytrenowany na zebranych danych. Całościowo, plan badawczy wskazuje na interdyscyplinarne podejście, łączące badania literaturowe, empiryczne i eksperymentalne. Mimo poprawnie dobranych narzędzi, trzeba niestety wskazać na kilka uchybień w opisie i realizacji metodyki, które mogą rzutować na wiarygodność wyników.

Przeglądy literatury wykonane przez Doktoranta zasługują na wysoką ocenę. Autor dokonał kompleksowej kwerendy w obszarach związanych z tematem rozprawy. Zakres przeglądów objął zarówno literaturę z dziedziny zarządzania produkcją, jak i literaturę z obszaru sztucznej inteligencji i uczenia maszynowego. Przeglądy nie ograniczają się do biernego streszczenia literatury, lecz zawierają elementy krytycznej analizy i syntezy. Autor umiejętnie wyciąga wnioski z wielu publikacji, wskazując np. różnice między podejściami stosowanymi w różnych kontekstach produkcyjnych. Doktorant nie poprzestał na ogólnikach, lecz wniknął w istotę badań różnych autorów i potrafił z nich zbudować spójny obraz stanu wiedzy. Dzięki temu dobrze umotywowował własną tezę, że algorytm GMLVQ, łączący zalety sieci neuronowych i uczenia metryki, może wypełnić pewną niszę. Osadzenie pracy w nurcie naukowym jest także widoczne poprzez liczne odwołania w tekście do teorii i definicji. Autor powołuje się na uznane koncepcje z nauk o zarządzaniu i jakości i pokazuje, jak Jego praca nawiązuje do tych pojęć lub je rozwija. Podobnie w warstwie technicznej, rozdział metodyczny odwołuje się do prac źródłowych opisujących algorytm GLVQ czy jego rozwinięcia.

Z kolei przeprowadzone i opisane wyniki badań ankietowych budzą wiele wątpliwości. Niejasna jest próba badawcza. Autor w pracy pisze, że do udziału w badaniu zaproszono 27 firm. Ponadto link do kwestionariusza ankietowego został rozesłany do 30 specjalistów na LinkedIn. Dalej jest mowa otrzymaniu łącznie 355 odpowiedzi. Z tego wynika, że w ramach jednego badanego przedsiębiorstwa mogło powstać kilka ankiet. Jeśli tak było, to wymaga komentarza. Nie ma też informacji o wielkości populacji generalnej, więc nie wiadomo, czy badana próba jest reprezentatywna. Brakuje też informacji o pilotażu i dacie przeprowadzenia badania. Autor przygotował pytania w kwestionariuszu na podstawie sformułowanych wcześniej hipotez. W związku z tym zawierają one pytanie o wpływ (tab. 2.3). To błąd metodyczny, bo hipotezy, zwłaszcza w zastosowanym w dalszej części pracy modelowaniu strukturalnym, bada się na podstawie związku (wpływu) jednej zmiennej na drugą. A tak w pracy badane są relacje zmiennych w postaci hipotez na inne hipotezy. Nie wiadomo też, jak powstały konstrukty, w skład których wchodzi te zmienne (rys. 2.2.). Jeśli nie są to konstrukty pochodzące z innych badań, to należało najpierw przeprowadzić

eksploracyjną analizę czynnikową w celu ich wyłonienia. Nie ma przeprowadzonej walidacji metod pomiaru zmiennych, np. w postaci testu rzetelności (alfa Cronbacha). Nie wiadomo, jak powstał model przedstawiony na rys. 2.7, w którym są trzy zmienne latentne: „subjective human decision factors”, „domain knowledge utilization”, „process ineffectiveness”. Nie były one wcześniej omawiane w formie konstruktów (poza „subjective human decision factors”). Nie uzasadniono związku między nimi, w szczególności, że zmienna „domain knowledge utilization” jest mediatorem między dwoma pozostałymi. Zmienne tworzące „domain knowledge utilization” oznaczone jako APC, CL, PCC i PVC są przedstawione jako zmienne niezależne (tab. 2.3, rys. 2.3, rys. 2.6), a w modelu PLS-SEM na rys. 2.7 występują jako zmienne zależne. Brakuje też uzasadnienia, dlaczego w modelowaniu strukturalnym wybrano PLS-SEM, a nie CB-SEM. Co prawda, sam model nie ma solidnych podstaw teoretycznych (uwaga wyżej), ale został zbudowany na zmiennych, które pochodzą z literatury. Ponadto próba badawcza jest dość duża (N=355), a konstrukty „subjective human decision factors” i „process ineffectiveness” oznaczone są jako refleksywne. Swoją drogą nie wiadomo, dlaczego „domain knowledge utilization” jest oznaczona jako zmienna formatywna (rys. 2.7), skoro podobnie jak „subjective human decision factors” nie mierzą różnych jej aspektów lub wymiarów.

W związku z powyższymi uwagami stwierdzam, że wyniki przedstawionych badań ankietowych budzą moje poważne wątpliwości do ich rzetelności i możliwości dalszego wykorzystania.

Kolejna uwaga dotyczy zastosowania do trenowania i testowania modelu zbioru danych, który wydaje się stosunkowo niewielki i jednorodny. Z treści rozprawy wynika, że dane pochodzą prawdopodobnie z jednego przedsiębiorstwa (lub z jednej branży). Nie przeprowadzono walidacji zewnętrznej, tj. model nie został sprawdzony na danych z innej firmy, innego sektora czy na szerszym, publicznie dostępnym zbiorze porównywalnym. To oznacza, że możliwość generalizowania wyników badania pozostaje pod znakiem zapytania. Model mógł „nauczyć się” specyfiki jednego przypadku, co ogranicza pewność, czy w innym środowisku przemysłowym również by zadziałał. Praktyką w badaniach nad systemami decyzyjnymi jest testowanie ich na zróżnicowanych scenariuszach lub przynajmniej zastosowanie metody podziału danych z wieloma powtórzeniami. Być może badania były tak poprowadzone, ale w rozprawie takich informacji brakuje. W projekcie eksperymentalnym nie uwzględniono porównania proponowanego modelu z innymi metodami. Autor skupił się na swojej metodzie (GMLVQ), przez co nie wiemy, czy osiągnięte wyniki są lepsze od innych możliwych podejść. Przydałoby się, aby model GMLVQ porównać np. z klasyczną siecią neuronową, z innymi metodami czy nawet drzewem decyzyjnym. Brak takiego porównania to istotna luka metodyczna eksperymentu, ponieważ nie można ocenić, na ile GMLVQ faktycznie wnosi przewagę nad innymi rozwiązaniami w tym zadaniu. Być może każda dobrze dobrana metoda uczenia nadzorowanego dałaby podobny efekt na tych danych.

Ograniczony zakres danych i testów powoduje, że prezentowane rezultaty nie mają pełnej mocy dowodowej, zaś brak pewnych elementów utrudnia krytyczne spojrzenie na uzyskane wyniki. Te braki i wcześniej wskazane uchybienia należałoby uzupełnić w dalszych badaniach Doktoranta.

Redakcja pracy

Od strony językowej i edytorskiej praca została przygotowana starannie. Styl narracji jest rzeczowy i zwięzły, adekwatny dla pracy naukowej w języku angielskim. Terminologia specjalistyczna (zarówno z zakresu zarządzania, jak i uczenia maszynowego) została użyta właściwie i konsekwentnie. Układ tekstu, formatowanie akapitów, tabel, wykresów, numeracja rozdziałów i podrozdziałów są prawidłowe. Nie dopatrzyłem się poważniejszych błędów edycyjnych; jeśli występowały literówki czy niejednorodności formatowania, miały one charakter marginalny.

Omówienie wyników, ich praktycznej wartości i ograniczeń

Wyniki uzyskane przez Doktoranta koncentrują się wokół oceny skuteczności zaproponowanego modelu GMLVQ w zadaniu klasyfikacji (rekomendacji) procesu wytwórczego. Zgodnie z treścią rozprawy, model osiągnął bardzo wysoką dokładność (100% skuteczności klasyfikacji). Oznacza to, że dla wszystkich przypadków testowych algorytm prawidłowo wskazał właściwy proces technologiczny. Taki wynik sugeruje, iż model idealnie dopasował się do danych, co może świadczyć o skuteczności metody. Autor interpretuje to jako potwierdzenie, że wykorzystanie GMLVQ do takiego typu problemu było trafne, ponieważ sieć nauczyła się zależności między cechami produktu a wyborem procesu na tyle dobrze, że nie popełnia błędów. Ponadto, dzięki właściwościom algorytmu GMLVQ, model dostarczył informacji o relewancji cech. Z analizy przytoczonej w rozprawie wynika przykładowo, że kluczowe cechy dla decyzji to np. rozmiar i geometria produktu, wymagany materiał oraz tolerancja dokładności. Taka informacja może być cenna, bo potwierdza intuicyjnie, że model kieruje się podobnymi przesłankami jak „ludscy eksperci”. 100% trafność budzi jednak uzasadnione podejrzenia co do nadmiernego dopasowania modelu (overfitting). W praktycznych zadaniach przetwarzania danych uzyskanie 100% trafności jest rzadkością. Zabrakło tu dokładniejszego raportu, np. podania liczby próbek, zastosowanej procedury walidacyjnej, liczby powtórzeń eksperymentu.

Z perspektywy wartości praktycznej proponowanego rozwiązania, Autor argumentuje, że opracowany system mógłby istotnie usprawnić proces decyzyjny w przedsiębiorstwach produkcyjnych. Gdyby narzędzie to wdrożyć, np. w formie modułu systemu CAD/CAM lub systemu wsparcia decyzji dla planistów, mogłoby ono automatycznie rekomendować najlepszą technologię wytwarzania dla nowego projektu produktu. Przyniosłoby to szereg potencjalnych korzyści takich, jak: przyspieszenie procesu planowania, zmniejszenie zależności od intuicji i doświadczenia pojedynczych ekspertów, bardziej obiektywne

i ustandaryzowane decyzje (wsparte analizą danych), a w efekcie także redukcję kosztów (poprzez unikanie nietrafionych decyzji technologicznych) oraz poprawę jakości i powtarzalności procesu produkcji. Tego rodzaju praktyczne implikacje są istotne, gdyż pokazują, że praca nie jest tylko teoretyczna, ale może rozwiązać realny problem i ma szansę znaleźć zastosowanie w przemyśle. Szkoda tylko, że wartość praktyczną wyników jest ograniczona ze względu na nieprzeprowadzenie walidacji w warunkach rzeczywistych (nie wynika to przynajmniej z treści pracy). Ponadto, co istotne z perspektywy standardów otwartej nauki, w rozprawie nie zawarto informacji o udostępnieniu kodu czy danych. Zwyczajowo coraz częściej praktykuje się, że autorzy prac zamieszczają np. link do repozytorium z kodem źródłowym algorytmu lub przykładowymi danymi. Tu tego zabrakło. Oczywiście, nie jest to formalny wymóg, ale transparentność badań bardzo zyskują, gdy inni mogą prześledzić kod, przetestować model lub dokonać replikacji badań.

Mimo powyższych krytycznych uwag, należy podkreślić, że żadne z tych ograniczeń nie przekreśla wartości naukowej rozprawy. Ograniczenia są w nauce czymś normalnym, zwłaszcza gdy eksploruje się nowatorskie podejścia. Ważne, że Autor osiągnął cel badawczy i wygenerował wyniki, które mogą stanowić punkt wyjścia do kolejnych badań i doskonalenia metody. Istotne jest, aby w przyszłości Doktorant podjął próby uzupełnienia tych braków, tj. przetestował model szerzej, dodał porównania i analizy wrażliwości, a także spróbował implementacji w realnym środowisku biznesowym.

IV. Wnioski końcowe

Analizowana rozprawa doktorska mgra inż. Fredricka Wanyamy Mumali jest wartościowym opracowaniem naukowym. Autor podjął aktualny i trudny temat z pogranicza zarządzania oraz sztucznej inteligencji, wykazując się przy tym dogłębnym zrozumieniem problemu. Przedstawił własne rozwiązanie i przeprowadził jego weryfikację na miarę dostępnych możliwości. Tym samym rozprawa spełnia kryterium oryginalności, gdyż dostarcza nowej wiedzy i narzędzi w obszarze nauk o zarządzaniu i jakości). Ponadto Doktorant wykazał się przy tym ogólną wiedzą teoretyczną w zakresie zarządzania (m.in. decyzje w zarządzaniu produkcją, rola czynników społecznych), a także umiejętnością samodzielnego prowadzenia badań naukowych. Świadczy o tym zaplanowany i wykonany proces badawczy obejmujący studia literaturowe, badania empiryczne i eksperymenty symulacyjne. Mimo wskazanych w recenzji niedoskonałości, praca jako całość reprezentuje poziom wymagany od rozpraw doktorskich. Należy mieć też świadomość, że część uwag przeze mnie wskazanych, może mieć charakter dyskusyjny.

Reasumując, wnioskuję do Wysockiej Rady Dyscypliny Nauk o Zarządzaniu i Jakości Politechniki Poznańskiej o dopuszczenie mgra inż. Fredricka Wanyamy Mumali do dalszego postępowania w przewodzie doktorskim, to jest do publicznej obrony rozprawy.