Dr hab. inż. Piotr Bańka, prof. PŚ
Wydział Górnictwa, Inżynierii Bezpieczeństwa
i Automatyki Przemysłowej
Politechnika Śląska

Gliwice, 3 marca 2026 r.

Recenzja
rozprawy doktorskiej mgr. inż. Parthkumara Anilbhai Parmara
pt.: „AI based modeling method for predicting failure related parameters in conveyor belts at mines"

Podstawa prawna wykonania recenzji: pismo Prorektor ds. Badań i Innowacji prof. dr hab. inż. Renaty Krzyżańskiej – zawiadomienie nr 03/01/D08/2026 o wyznaczeniu na Recenzenta w postępowaniu w sprawie nadania stopnia doktora, w oparciu o uchwałę Rady Dyscypliny Naukowej Inżynieria Środowiska, Górnictwo i Energetyka nr 365/17/RDND08/2024-2028 z dnia 21 stycznia 2026 r. oraz w związku z art. 190 ust. 2 i art. 183 ustawy z dnia 20 lipca 2018 r. Prawo o szkolnictwie wyższym i nauce.

1. Ogólna charakterystyka, tematyka rozprawy

Recenzowana rozprawa składa się z 7 rozdziałów, poprzedzonych stroną tytułową (z drobnym błędem dotyczącym dziedziny nauki), oświadczeniem o autorstwie, streszczeniami w językach angielskim i polskim, podziękowaniem, spisem treści, spisami rysunków, tabel oraz nienumerowanym rozdziałem (w spisie treści zatytułowanym „Wstęp i zakres pracy", co jest jedynym wpisem w języku polskim, z kolei w treści pracy „Introduction") – wstępem, zawierającym także krótkie streszczenia kolejnych rozdziałów. Po siódmym rozdziale rozprawy znajduje się obszerny spis wykorzystanej literatury, liczący 287 pozycji. Doktorant jest współautorem dwóch z cytowanych artykułów.

Promotorami rozprawy są: Pani prof. dr hab. inż. Anna Burduk z Wydziału Mechanicznego i Pan dr hab. inż. Leszek Jurdziak, prof. uczelni z Wydziału Geoinżynierii, Górnictwa i Geologii Politechniki Wrocławskiej.

Tematyka rozprawy dotyczy istotnego problemu utrzymania ruchu przenośników taśmowych w zakładach górniczych. Autor w celu przewidywania awarii taśm przenośnikowych zaproponował wykorzystanie w tym celu jednej z metod sztucznej inteligencji – sieci neuronowej LSTM.

W nowoczesnym górnictwie, zarówno odkrywkowym, jak i głębinowym, przenośniki taśmowe stanowią podstawowe ogniwo ciągu technologicznego. Są one zintegrowanym elementem systemu produkcyjnego, którego sprawność bezpośrednio przekłada się na wyniki finansowe i bezpieczeństwo operacyjne kopalni. Szczególne znaczenie mają przenośniki odstawy głównej. W przeciwieństwie do przenośników oddziałowych, które obsługują pojedyncze przodki, odstawa główna kumuluje urobek z całego zakładu i transportuje go w kierunku szybu lub na powierzchnię, z reguły do zakładu wzbogacania urobku.

Wystąpienie awarii przenośników taśmowych odstawy głównej z reguły powoduje znaczne zakłócenia w produkcji zakładu górniczego. Ze względu na liniowy charakter transportu taśmowego, uszkodzenie jednego elementu ciągu technologicznego powoduje natychmiastowe zatrzymanie wszystkich urządzeń poprzedzających.

Awaria jednego z przenośników odstawy głównej powoduje perturbacje, które mają wpływ na funkcjonowanie całego zakładu górniczego:

- wstrzymanie urabiania: ponieważ systemy oddziałowych zbiorników wyrównawczych mają ograniczoną pojemność, brak możliwości odstawy urobku zmusza do zatrzymania urabiania kombajnami chodnikowymi i ścianowymi,
- straty czasowe i wydajnościowe: ponowny rozruch całego ciągu technologicznego po usunięciu awarii jest procesem czasochłonnym i energochłonnym,
- koszty stałe: pomimo przestoju w wydobyciu, zakład górniczy nadal generuje koszty związane m.in. z wentylacją, odwadnianiem, amortyzacją lub dzierżawą maszyn i urządzeń oraz wynagrodzeniami załogi, która nie może wykonywać swoich zadań produkcyjnych.

Historycznie rzecz biorąc, do niedawna w celu zapewnienia bezawaryjnej pracy maszyn i urządzeń wykorzystywano dwa sposoby ich konserwacji:

- obsługi reaktywnej, polegającej na przeprowadzaniu napraw po wystąpieniu awarii,
- obsługi prewencyjnej, zakładającej wykonywanie przeglądów, konserwacji oraz wymiany części zgodnie z ustalonymi harmonogramami.

Oba podejścia mają istotne wady. Przeprowadzanie napraw dopiero po wystąpieniu awarii z reguły powoduje przedłużenie jej trwania i wiąże się z dużymi kosztami usunięcia usterki oraz utratą zysków przedsiębiorstwa. Z kolei wykonywanie konserwacji zgodnie z ustalonym harmonogramem może generować nadmiarowe koszty działań serwisowych, kiedy są one wykonywane zgodnie z planem, a w rzeczywistości nie są potrzebne.

W celu zminimalizowania ryzyka nieplanowanych przestojów, w ostatnich latach wprowadzana jest strategia predykcyjnego utrzymania ruchu. Są to działania mające na celu zwiększenie efektywności wykorzystania maszyn i urządzeń poprzez minimalizację nieplanowanych przestojów, oparte na obserwacji stanu maszyn, w celu zapobiegania ich awariom oraz przewidywania czasu podjęcia niezbędnych działań związanych z przeglądami i konserwacją. Nowoczesne systemy przewidujące awarie oparte są między innymi na technologiach sztucznej inteligencji. Pozwala to na przyspieszenie procesu analizy zgromadzonych danych oraz pozwala wykorzystać je do podejmowania decyzji o konieczności przeprowadzenia określonych prac związanych z utrzymaniem ruchu maszyn i urządzeń.

W odniesieniu do przenośników taśmowych strategia predykcyjnego utrzymania ruchu powinna przede wszystkim obejmować:

- monitoring węzłów przesypowych oraz napędów przenośników,
- kontrolę stanu taśmy przenośnikowej,
- analizę pracy krążników, przede wszystkim w celu wykrycia zatartych łożysk.

W świetle powyższych uwag, podjęcie przez Autora rozprawy tematyki związanej z opracowaniem metody wykorzystującej sztuczną inteligencję do przewidywania konieczności napraw taśm przenośnikowych uważam za bardzo celowe, biorąc pod uwagę zarówno względy poznawcze jak i aplikacyjne.

2. Zawartość merytoryczna rozprawy doktorskiej

We wprowadzeniu do pracy Autor podkreślił znaczenie bezawaryjnej pracy przenośników taśmowych we współczesnych zakładach górniczych. Ze względu na pracę tych przenośników w bardzo trudnych warunkach występujących w kopalniach, zaproponował wdrożenie predykcyjnego utrzymania ruchu opartego na jednej z metod sztucznej inteligencji – sieciach neuronowych. Analiza trendów publikacyjnych potwierdziła rosnące znaczenie sieci neuronowych w modelowaniu, a także w zagadnieniach dotyczących górnictwa. Co roku wzrasta również liczba artykułów poświęconych wykorzystaniu metod sztucznej inteligencji w konserwacji predykcyjnej. Zaprezentowane to zostało na rysunku 3 (który został opatrzony błędną nazwą – powtórzoną z rysunku 2).

Wprowadzenie zostało zakończone krótkim streszczeniem kolejnych rozdziałów rozprawy.

W pierwszym rozdziale rozprawy zostały przedstawione podstawowe informacje dotyczące systemów przenośników taśmowych. Krótko scharakteryzowano osiem podstawowych typów przenośników wykorzystywanych w różnych gałęziach przemysłu, a także rodzaje taśm przenośnikowych. Nieco więcej uwagi poświęcono omówieniu budowy taśmy przenośnikowej wykorzystywanej w zakładach górniczych. Autor zwrócił uwagę, że pomimo nowoczesnej konstrukcji taśm przenośnikowych i zastosowania do ich wytwarzania materiałów o dużej wytrzymałości i trwałości, na bezawaryjne ich funkcjonowanie bardzo istotny wpływ ma sposób ich konserwacji. Wymienił szereg czynności, które należy wykonywać w celu osiągnięcia zakładanej niezawodności taśm przenośnikowych:

- kontrole wizualne,
- odpowiedni naciąg taśmy,
- odpowiednie prowadzenie taśmy,
- pomiary metodami magnetycznymi, wykorzystanie systemów rentgenowskich do wykrywania uszkodzeń wewnętrznych oraz stosowanie innych zaawansowanych systemów, m.in. termografii podczerwonej oraz systemów IoT i sztucznej inteligencji do monitorowania stanu taśmy w czasie rzeczywistym.

W dalszej części rozdziału przedstawiony został obszerny przegląd literatury poświęconej problematyce zużycia taśm przenośnikowych i ich awarii. Na podstawie rezultatów powyższej analizy literaturowej sporządzono diagram Ishikawy. Zgodnie z tym diagramem przyczyny uszkodzenia taśm przenośnikowych można podzielić na sześć kategorii, związanych z:

- czynnikiem ludzkim,
- parametrami transportowanych materiałów,
- charakterystyką taśm przenośnikowych i ich połączeń,
- czynnikami organizacyjnymi,
- parametrami przenośników,
- warunkami środowiskowymi.

Wnioski z przeprowadzonych analiz wskazują, że podstawą wydłużenia żywotności systemów przenośników taśmowych jest połączenie proaktywnej konserwacji z nowoczesnymi systemami monitorowania, co pozwala na wczesne wykrywanie drobnych uszkodzeń taśmy przenośnikowej, przed ich powiększeniem się do wielkości powodującej poważną awarię.

W drugim rozdziale rozprawy został przedyskutowany problem doboru odpowiedniej metody sztucznej inteligencji do zagadnienia konserwacji predykcyjnej, będącego przedmiotem rozprawy. Autor przedstawił wyniki studiów literaturowych, które jednoznacznie wskazują, że metody sztucznej inteligencji, a w szczególności sieci neuronowe, w wielu przypadkach okazały się bardzo dobrym narzędziem do odkrywania nieliniowych zależności podczas analizy zaszumionych danych pochodzących z zakładów górniczych. Przytoczone zostały także publikacje dotyczące zastosowania sieci neuronowych do modelowania uszkodzeń przenośników taśmowych zainstalowanych w kopalniach. Odnosząc się do stwierdzeń Doktoranta zawartych w tym rozdziale, zgadzając się, że próba wykorzystania modeli regresji liniowej do opisu zależności nieliniowych jest skazana na niepowodzenie, należy zwrócić uwagę, że w takich przypadkach można podjąć próbę wykorzystania modeli nieliniowych. Natomiast w przypadku, gdy liczba obserwacji jest mniejsza od liczby parametrów modelu trudno oczekiwać dobrych rezultatów nawet w przypadku użycia metod sztucznej inteligencji.

W dalszej części rozdziału omówione zostały podstawowe rodzaje sieci neuronowych oraz ich zalety i wady. Do będącego przedmiotem badań zagadnienia konserwacji predykcyjnej taśm przenośnikowych Doktorant zdecydował się zastosować sieć LSTM, z krokiem czasowym wynoszącym 1. Oznacza to tzw. drobnoziarnistą rozdzielczość – model reaguje na każdą zmianę sygnałów wejściowych, zamiast je uśredniać z dłuższego okna czasowego. Wybór sieci LSTM został w sposób przekonujący uargumentowany. Podane zostały również pewne ograniczenia wynikające z zastosowania tego typu sieci.

W trzecim rozdziale dysertacji zostały przedstawione jej zakres i cele oraz przyjęta metodologia badań.

Celem naukowym rozprawy było opracowanie metody wykorzystującej rozwiązania oparte na sztucznej inteligencji przewidywania parametrów związanych z awariami taśm przenośnikowych, w tym wielkości uszkodzeń i częstości ich występowania, poprzez wykorzystanie charakterystyki operacyjnej i historycznych danych dotyczących przeprowadzonych konserwacji taśm, uzyskanych z wybranych zakładów górniczych.

Celem aplikacyjnym rozprawy była natomiast poprawa wydajności operacyjnej kopalń poprzez opracowanie opartego na sztucznej inteligencji systemu konserwacji predykcyjnej taśm przenośnikowych. Naprawy zapobiegawcze oparte na

przewidywanym stanie taśm mogą zapobiegać ich dużym uszkodzeniom i awaryjnym przestojom przenośników taśmowych, a jednocześnie umożliwiają bardziej efektywny przydział zasobów, wydłużają żywotność taśm i poprawiają bezpieczeństwo, zapewniając bezawaryjne działanie w środowiskach zakładów górniczych.

Realizując pracę Autor wykorzystał dane pochodzące z kopalni węgla brunatnego, w której wykonywano wizualne kontrole stanu taśm przenośnikowych oraz dane z kopalni wapienia, w której do kontroli stanu taśmy zastosowano nowoczesny system diagnostyczny DiagBelt+.

W rozdziale tym Doktorant bardzo szczegółowo przedstawił także zakres pracy, wyczerpująco uzasadniając celowość realizacji jej kolejnych etapów.

Autor zrezygnował z formułowania tezy rozprawy. Uważam, że podawanie tezy nie jest konieczne, stąd nie należy tego traktować jako uchybienie.

W czwartym rozdziale pracy przedstawione zostały rezultaty predykcyjnego modelowania awarii taśm przenośnikowych z wykorzystaniem do trenowania sieci neuronowej danych o uszkodzeniach uzyskanych z wizualnych kontroli przeprowadzanych przez służby zakładu górniczego – kopalni węgla brunatnego w Polsce.

Wykorzystując wyniki studiów literaturowych wytypowano 11 zmiennych wejściowych: długość taśmy przenośnikowej, długość danego odcinka taśmy, rodzaj transportowanego materiału, nachylenie przenośnika, nowy/używany odcinek taśmy, procentowe zużycie odcinka taśmy (w odniesieniu do szacowanej żywotności), czas od poprzedniej naprawy, liczba drobnych napraw w danym okresie, skumulowana liczba drobnych napraw przed tym okresem, liczba przeciętych linek stalowych, skumulowana liczba przeciętych linek przed tym okresem. Zmiennymi na wyjściu sieci neuronowej były: czas użytkowania od ostatniej naprawy, liczba drobnych napraw w tym okresie, skumulowana liczba drobnych napraw danego odcinka taśmy, liczba uszkodzonych linek stalowych w okresie od ostatniej naprawy, skumulowana liczba przeciętych linek w danym odcinku taśmy. Zgromadzony zbiór danych zawierający 927 rekordów, podzielony został na zbiór danych uczących (717 przypadków) i zbiór danych testowych (210 przypadków).

Autor przeprowadził analizę statystyczną zgromadzonych danych, między innymi obliczył macierz korelacji Pearsona wszystkich 16 parametrów.

W badaniach zostało uwzględnione pięć modeli sieci różniących się parametrami na wyjściu. Dodatkowo, w celu określenia jakości rozpatrywanych modeli sieci zbiór

danych został podzielony na trzy podzbiory. Przeprowadzona w ten sposób ocena jakości prognozowania danego modelu (trenowanego z wykorzystaniem różnych zestawów danych wejściowych) pozwoliła stwierdzić, czy można oczekiwać zadowalających rezultatów predykcji podczas wykorzystywania sieci LSTM do konserwacji predykcyjnej taśm przenośnikowych w rzeczywistych warunkach zakładów górniczych. Niestety, z drugiej strony spowodowało to znaczne ograniczenie liczebności zbiorów wykorzystywanych do trenowania sieci.

Podział danych uczących i testowych na trzy podzbiory spowodował, że rozpatrywanych było ogółem 15 modeli sieci.

Dobierając architekturę sieci neuronowej przeanalizowano różne jej warianty, zmieniając liczbę warstw ukrytych, liczbę neuronów w tych warstwach, funkcje aktywacji, zastosowane algorytmy minimalizacji błędów uczenia. W celu porównania zdolności predykcyjnych wytrenowanych sieci neuronowych obliczano wartość trzech wskaźników wskazujących udział procentowy prognoz (dla zbioru 210 przypadków):

- A: w których błąd względny wynosił poniżej 50%,
- B: w których błąd względny wynosił od 50% do 100%,
- C: w których błąd względny wynosił powyżej 100%,

w porównaniu z danymi kopalnianymi. Określana była także mediana błędu względnego prognozy.

Wszystkie wyniki obliczeń zostały bardzo czytelnie zaprezentowane, zarówno w formie tabelarycznej jak i w postaci wykresów. W przypadku zestawień tabelarycznych, podając wartości procentowe warto było zwiększyć precyzję liczb, bo obecnie nie sumują się one do 100%.

Rozdział kończy się trafnymi wnioskami i spostrzeżeniami. Istotne jest stwierdzenie Doktoranta, że lepsze rezultaty będą osiągnięte, jeżeli do trenowania sieci neuronowej zostaną wykorzystane dane pozyskane z nowoczesnych metod diagnozy stanu taśmy przenośnikowej, na przykład magnetycznych lub wykorzystujących promienie rentgena.

W rozdziale piątym przedstawione zostały podstawowe informacje dotyczące magnetycznego systemu diagnostycznego do monitorowania stanu taśm przenośnikowych DiagBelt+. Omówione zostały zasady działania systemu, jego budowa, sposób analizy uzyskiwanych danych oraz dokonany został przegląd literatury poświęconej monitorowaniu stanu taśmy przenośnikowej tym sposobem. Autor zwrócił uwagę, że system DiagBelt+ stanowi znaczący postęp w diagnostyce

taśm przenośnikowych. Wykorzystując technologię czujników magnetycznych do wykrywania wewnętrznych uszkodzeń taśm można wyeliminować ograniczenia tradycyjnych kontroli wizualnych i tym samym zwiększyć dokładność predykcji stanu taśmy przenośnikowej opracowanymi modelami wykorzystującymi sieci neuronowe LSTM, szczegółowo opisanymi w rozdziale czwartym.

W szóstym rozdziale pracy przedstawione zostały rezultaty predykcji stanu taśmy przenośnikowej z wykorzystaniem modelu trenowanego w oparciu o zapisy uzyskane z systemu DiagBelt+ (3 sesje pomiarowe). Dane pochodziły z odkrywkowej kopalni wapienia. Długość taśmy wynosiła 7200 metrów, składała się ona z 20 odcinków o długościach od 59 m do 450 m.

W przypadku tych badań lista zmiennych wejściowych obejmowała 6 parametrów: długość i szerokość taśmy przenośnikowej, wiek, długość i numer skanowanego odcinka taśmy, numer skanu. Zmiennymi na wyjściu sieci neuronowej były: gęstość uszkodzeń na metr długości taśmy, liczba uszkodzeń danego odcinka, powierzchnia oraz długość i szerokość uszkodzeń. Ogółem zgromadzono 929 rekordów, które podzielono na zbiór danych uczących (534 przypadki) oraz zbiór danych testowych (395 przypadków).

Analogicznie jak w przypadku badań wykorzystujących wyniki kontroli wizualnych, Autor przeprowadził analizę statystyczną zgromadzonych danych, między innymi obliczył macierz korelacji Pearsona wszystkich 11 parametrów. Uwzględnione zostały cztery modele sieci różniące się parametrami na wyjściu. Dobierając architekturę sieci neuronowej przeanalizowano różne jej warianty, zmieniając liczbę warstw ukrytych, funkcje aktywacji i zastosowane algorytmy minimalizacji. Analogicznie jak w przypadku obliczeń, których wyniki zostały przedstawione w rozdziale 4, wyznaczano wartość trzech wskaźników: A, B i C oraz medianę błędu względnego prognozy.

W dalszej części rozdziału Autor zaprezentował możliwość praktycznego wykorzystania opracowanej metody prognozowania stanu taśmy przenośnikowej. W tym celu dołączył do zbioru danych uczących wyniki trzeciego skanowania taśmy przenośnikowej systemem DiagBelt+. Wytrenowana sieć została wykorzystana do predykcji stanu taśmy w kolejnych dwóch latach. Przeprowadzona dyskusja otrzymanych wyników pozwoliła stwierdzić, że sieć neuronowa LSTM generuje wiarygodne prognozy stanu taśmy przenośnikowej umożliwiając podejmowanie trafnych decyzji o konieczności przeprowadzania jej napraw.

Rozdział kończy interesujące porównanie predykcji gęstości uszkodzeń taśmy przenośnikowej wykonanych modelami regresji oszacowanymi z wykorzystaniem wyników skanowania magnetycznego (model R1) oraz z wykorzystaniem tych wyników uzupełnionych o rezultaty prognozy siecią neuronową (model R2). Oba modele cechują się podobną tendencję wzrostową i pokazują zwiększające się zużycie taśmy przenośnikowej w miarę upływu czasu, co jest zgodne z wynikami obserwacji. Niestety, na wykresie przedstawionym na rysunku 6.16 trudno dostrzec różnice pomiędzy rezultatami obliczeń modelami R1 i R2, o których pisze Autor we fragmencie tekstu zamieszczonym poniżej rysunku.

W siódmym rozdziale przedstawione zostało podsumowanie przeprowadzonych badań. Stwierdzenia zawarte w tym rozdziale są poprawnie sformułowane. Wydaje się, że porównanie warunków pracy przenośników i sposobu kontroli stanu taśmy w dwóch wybranych do badań zakładach górniczych mogło znaleźć się w jednym z początkowych rozdziałów pracy.

Podsumowując merytoryczną charakterystykę rozprawy, chciałbym podkreślić staranność jej przygotowania. Autor omówił wszystkie istotne zagadnienia. Również redakcja pracy jest na dobrym poziomie. Zwraca uwagę odmienny układ pracy od powszechnie stosowanego wzoru – w miarę omawiania kolejnych zagadnień wielokrotnie występuje w niej przegląd literatury. Uważam, że taki układ pracy zwiększa jej czytelność.

3. Uwagi i komentarze

Podczas lektury recenzowanej rozprawy nasunęło mi się kilka pytań i uwag.

1. Odnosząc się do stosunkowo dużych błędów oszacowań, Doktorant trafnie wymienił ich podstawowe przyczyny, m.in. małą liczbę danych wykorzystywanych do trenowania sieci neuronowych, brak wiarygodnych informacji o historii danego odcinka taśmy oraz wykorzystywanie jako zmiennej wejściowej czasu użytkowania taśmy zamiast masy i rodzaju przetransportowanego materiału. Czy w przypadku tego ostatniego parametru nie istnieje możliwość pozyskania z zakładu górniczego informacji o wydobyciu oddziałowym względnie całej kopalni?
2. Doktorant w rozdziale 2 przeprowadził analizę różnych metod sztucznej inteligencji. W oparciu o jej wyniki wybrał do predykcji stanu taśmy przenośnikowej sieć neuronową LSTM. To oczywiście bardzo dobry wybór, jednak

w prowadzonych badaniach problemem była stosunkowo mała liczba danych, zarówno w przypadku rezultatów inspekcji wizualnych jak i skanowania magnetycznego. Sieci LSTM ze względu na dużą liczbę parametrów są bardzo podatne, szczególnie w przypadku małych zbiorów danych uczących, na tzw. przeuczenie. Czy w związku z tym Autor nie próbował wykorzystać prostszych sieci GRU, które często okazują się lepsze w przypadku konieczności wykorzystania do trenowania małych zbiorów danych?

3. Sieć neuronowa LSTM została zaimplementowana z wykorzystaniem języka Python i szeregu bibliotek: TensorFlow, NumPy, Keras, Pandas, Matplotlib i scikit-learn. Czy Doktorant jest autorem programu wykorzystywanego w prowadzonych badaniach? Jeżeli tak, to czy aktualna funkcjonalność programu umożliwia wdrożenie go w zakładach górniczych?
4. Wyniki obliczeń wskaźnika korelacji Pearsona zmiennych niezależnych oraz zmiennych zależnych przedstawione w tabeli 4.3 pokazują, że niektóre z tych zmiennych są bardzo silnie skorelowane, np. X_9 i X_{11} oraz Y_3 i Y_5. Czy Doktorant zastanawiał się nad usunięciem ich z modelu? Podobna uwaga dotyczy niektórych zmiennych zamieszczonych w tabeli 6.5.
5. Cztery z pięciu modeli przedstawionych w tabeli 4.6 posiadają dwa wyjścia. W zastosowaniach sieci neuronowych do regresji często lepiej sprawdzają się sieci zawierające tylko jedno wyjście. Co było powodem zaprojektowania sieci z dwoma wyjściami? Analogiczna uwaga dotyczy modelu 4 z tabeli 6.6.
6. Czy architektury sieci podane w tabelach 4.10 i 6.7 były jedynymi rozważanymi? Czy zawsze były dwa neurony w warstwie wyjściowej? Co skłoniło Autora do przyjęcia tak dużej liczby warstw ukrytych, wynoszącej 7? Dla większości problemów wystarczające jest przyjęcie 3 warstw ukrytych. Każda kolejna warstwa ukryta zwiększa problemy związane z nauką sieci w sytuacji małej liczby danych. Ponadto, w celu obiektywnego porównania różnych wariantów sieci często wydziela się jeszcze jeden zbiór, walidacyjny, który służy tylko do oceny jakości predykcji.
7. Najczęściej stosowanymi proporcjami pomiędzy liczebnością zbioru uczącego i testowego to odpowiednio 80% i 20% całkowitej liczby danych. Jaki był powód przyjęcia innego podziału, podanego na stronie 58 rozprawy? Ponadto w klasycznych sieciach neuronowych dane testowe mogą być dowolnie wylosowane ze zbioru danych. Natomiast w sieciach LSTM dane testowe powinny

następować chronologicznie po danych uczących. W pracy nie znalazłem informacji jak dokonywano podziału na dane uczące i testowe w przypadku wykorzystywania informacji z inspekcji wizualnych stanu taśmy przenośnikowej.

8. W jakim celu w przypadku analizy danych uzyskanych z systemu DiagBelt+ przyjęto zmienne X_1 i X_2? Wartości te są niezmienne i nic nie wnoszą do modelu.
9. Sprawdzając możliwość praktycznego wykorzystania opracowanej metody prognozowania stanu taśmy przenośnikowej Autor dołączył do zbioru danych uczących wyniki trzeciego skanowania taśmy przenośnikowej systemem DiagBelt+. Jakie zastosowano w tym przypadku kryterium zatrzymania uczenia sieci w celu uniknięcia jej nadmiernego dopasowania do danych uczących?
10. Czy przy szacowaniu parametrów modelu regresji R2 zostały pominięte wartości odbiegające od pozostałych? Zastanawiająca jest bardzo zbliżona postać modeli R1 i R2.

Pragnę podkreślić, że wysoko oceniam merytoryczny poziom recenzowanej pracy. Sformułowane uwagi nie zmieniają tej wysokiej oceny rozprawy. W oparciu o analizę przedłożonej pracy stwierdzam, że Doktorant rzetelnie wykonał zaplanowany przez siebie zakres badań i analiz. Umożliwiło to zrealizowanie założonych celów pracy. Treść rozprawy świadczy o jego dobrej znajomości opisywanej problematyki.

Wniosek końcowy

W konkluzji wyrażam opinię, że recenzowana rozprawa doktorska mgr. inż. Parthkumara Anilbhai Parmara p.t. **„AI based modeling method for predicting failure related parameters in conveyor belts at mines"** dotyczy dyscypliny naukowej Inżynieria Środowiska, Górnictwo i Energetyka. Praca ma charakter poznawczy i utylitarny, stanowi oryginalne rozwiązanie problemu naukowego sformułowanego w temacie rozprawy, potwierdza, że Autor posiada szeroką wiedzę teoretyczną i umiejętność prowadzenia badań naukowych w zakresie dyscypliny Inżynieria Środowiska, Górnictwo i Energetyka.

Analizowana rozprawa doktorska spełnia wymagania stawiane pracom doktorskim w *Ustawie z dnia 20 lipca 2018 r. Prawo o szkolnictwie wyższym i nauce*. Na tej podstawie wnoszę do Rady Dyscypliny Inżynieria Środowiska, Górnictwo i Energetyka Politechniki Wrocławskiej o dopuszczenie jej do publicznej obrony.

[redacted]