

Częstochowa, dn. 4 września 2023 r.

prof. dr hab. inż. Rafał Scherer
Katedra Inteligentnych Systemów Informatycznych
Wydział Inżynierii Mechanicznej i Informatyki
Politechnika Częstochowska
al. Armii Krajowej 36
42-200 Częstochowa

Recenzja

rozprawy doktorskiej mgr inż. Macieja Gołgowskiego, pt.: Wybrane metody uczenia maszynowego w zadaniach wykrywania anomalii procesów.

Niniejszą recenzję opracowano na wniosek Rady Dyscypliny Naukowej Informatyka Techniczna i Telekomunikacja Wojskowej Akademii Technicznej im. Jarosława Dąbrowskiego. Promotorem jest prof. dr hab. inż. Stanisław Osowski.

1. Charakterystyka tematu, celu i tezy badawczej rozprawy

Wykrywanie anomalii jest ważnym narzędziem w wielu dziedzinach życia, zarówno w nauce, jak i technice i biznesie. Może być wykorzystane w cyberbezpieczeństwie, monitorowaniu procesów przemysłowych, medycynie, finansach, sieciach społecznościowych, monitorowaniu środowiska naturalnego itd. W rozprawie występują przykłady monitorowania maszyn, diagnostyki medycznej oraz wykrywania prób manipulacji informacjami. Wykrywanie anomalii jest istotnym narzędziem do identyfikacji nieprawidłowości, które mogą mieć negatywne skutki w różnych dziedzinach życia i gospodarki.

2. Zawartość rozprawy

Recenzowana praca mgr inż. Macieja Gołgowskiego składa się ze streszczenia, spisu treści, sześciu rozdziałów oraz bibliografii. Dokument liczy 104 strony.

Pierwszy rozdział jest krótkim wprowadzeniem do tematyki. Autor definiuje pojęcie anomalii procesu, istotę detekcji anomalii oraz omawia problemy związane ze stosowaniem metod klasyfikacji do wykrywania anomalii takie jak częste niezbalansowanie danych dotyczących anomalii, trudności w definiowaniu przebiegów normalnych i anormalnych, czy określeniu

zakresu zmienności przebiegów normalnych. Metody wykrywania anomalii podzielono na odległościowe oraz bazujące na gęstości rozkładu. Podano cel pracy, którym jest stworzenie nowych metod wykrywania anomalii procesów głównie z wykorzystaniem transformacji falkowych ciągłych i dyskretnych do generacji cech i użycie różnych klasyfikatorów do wykrywania anomalii. Rozdział pierwszy kończy się przeglądem zawartości rozprawy.

Rozdział drugi prezentuje metody uczenia maszynowego stosowane w badaniach. Omówiono transformację falkową ciągłą oraz dyskretną. Autor przybliżył klasyfikatory używane w eksperymentach przeprowadzonych w dalszych rozdziałach, a mianowicie: losowy las drzew decyzyjnych, zespół klasyfikatorów gradient boosting, klasyfikator SVM, klasyfikator k-NN, klasyfikator oparty na procesie gaussowskim, sieć wielowarstwowy perceptron nieliniowy oraz naiwny klasyfikator Bayesa. Na końcu omówione zostały dokładniej sieci spłotowe używane do analizy sygnałów, głównie obrazów. Podano przykład struktury AlexNet oraz wymieniono szereg późniejszych popularnych modeli CNN dostępnych w literaturze.

Rozdział 3 omawia wykrywanie anomalii w sygnałach EKG. Zaprezentowano krótki przegląd literatury dotyczącej wykrywania analizy EKG przy pomocy metod uczenia maszynowego. Omówiono sam sygnał EKG z pięcioma podstawowymi załawkami. Podkreślono dlaczego transformacja falkowa nadaje się dobrze do analizy sygnałów EKG przez jego nietypową charakterystykę. Do badań zastosowano zbiory danych pochodzące ze strony <https://physionet.org/> ze 162 nagraniami sygnału EKG. Próbkę były podzielone na trzy grupy: arytmie, niewydolność serca oraz pracę normalną. Sygnały były próbkowane z częstotliwością 128 herców. Doktorant podzielił dane w stosunku 70 do 30 na uczące i testujące. Przybliżono sposoby ekstrakcji cech za pomocą z wykorzystaniem szybkiej transformacji Fouriera, algorytmu Pana-Tompkinsa, oraz z zastosowaniem dyskretnej dekompozycji falkowej (DWT). W wyniku DWT uzyskuje się 78 cech (13 miar statystycznych dla sześciu sygnałów). Automatycznie dobrane cechy sygnału zostały poddane analizie zgodności chi-kwadrat. Wybrane cechy zostały użyte jako wektor wejściowy dla ośmiu popularnych klasyfikatorów. Eksperymenty przeprowadzono na zestawach 12, 24, 48 oraz 78 cech.

Autor wykonał eksperymenty dla wszystkich kombinacji klasyfikatorów i zestawów cech pokazujące, że najlepiej zachowywał się zestaw 24 cech i klasyfikator random forest. Dla tego zestawu cech, z sześciu najlepiej działających klasyfikatorów Autor stworzył zespół oparty na głosowaniu większościowym, co dalej poprawiło jakość klasyfikacji.

Ciągła transformacja falkowa pozwoliła wyekstrahować cechy w formie obrazu, który mógł być analizowany przez standardowe sieci spłotowe 2D używane do obrazów. Obrazy cech zostały zmniejszone do standardowych rozdzielczości używanych przez obecne sieci CNN. W badaniach użyto sieć o trzech warstwach spłotowych z funkcją ReLU i funkcją max pooling. Meta parametry sieci spłotowej zostały wybrane eksperymentalnie, natomiast nie podano przykładowych zależności jak zmieniała się dokładność klasyfikacji w zależności od meta parametrów sieci. Takie podejście polegające na analizie bitmapy cech jak zwykłego obrazu nie dało dobrych wyników. I tutaj Autor podaje możliwe powody: dużą kompresję wejściowego obrazu cech oraz małą liczebność zbiorów danych.

W dalszych badaniach zostały użyte gotowe popularne sieci spłotowe dostępne w sieci Internet, nauczone klasyfikacji 1000 klas obiektów wizualnych, czyli zbioru ImageNet. Zmieniono oczywiście liczbę wyjść, dostosowując struktury do rozważanego problemu. Uczono jedynie warstwy w pełni połączone odpowiedzialne za klasyfikację. Osiem takich architektur CNN po nauczeniu zadania wykrywania anomalii połączono w zespół, którego wyjście ustala się przez głosowanie większościowe. Uzyskane wyniki są porównywalne z najlepszymi wynikami uzyskanymi przez klasyfikatory tradycyjne. Natomiast, odbyło się to najprawdopodobniej za cenę bardzo dużej złożoności obliczeniowej takiego zespołu.

Rozdział 4 poświęcony jest wykrywaniu uszkodzeń łożysk tocznych poprzez analizę sygnałów pochodzących z czujników akcelerometrycznych. Zostały użyte dane pochodzące z serwisu Mendeley Data, zawierające cztery rodzaje uszkodzeń i stan normalny. Autor omówił problemy z wykorzystaniem podejścia opartego o transformację Fouriera, oraz dlaczego w tym przypadku transformacja falkowa powinna lepiej sprawdzić się przy analizie takiego procesu. Ogólnie podejście w tym rozdziale jest podobne jak w przypadku analizy sygnałów EKG, to znaczy tworzone są cechy z zastosowaniem DWT oraz CWT. Cechy dyskretne tworzone są automatycznie i poddane analizie testem chi-kwadrat w celu wyliczenia ważności poszczególnych cech. Wektory takich cech były danymi wejściowymi do sześciu popularnych klasyfikatorów oraz na ich bazie stworzono zespół oparty o głosowanie większościowe. W następnym kroku, podobnie jak poprzednio, zastosowano sieci splotowe do analizy obrazu z danymi wejściowymi w postaci obrazów powstałych w wyniku CWT. I znowu, początkowo użyto sieci splotowej tworzonej (uczonej) od podstaw, a następnie użyto metody transfer learning z użyciem ośmiu popularnych sieci splotowych wstępnie uczonych na zbiorze ImageNet.

Rozdział 5 dotyczy wykrywania obrazów wygenerowanych i zmanipulowanych przez systemy uczące się. Opisano pokrótce sieci GAN służące do tworzenia takich obrazów. W badaniach użyto zbioru danych FaceForensics++. W zbiorze danych występowały materiały tworzone przez metodę FaceSwap, gdzie sieć przenosiła obraz wykryty jako twarz z wideo wejściowego do wideo wyjściowego, przez metodę DeepFake, która używa autoenkodera do tworzenia syntetycznego obrazu, oraz metody Face2Face, która zmienia ekspresję twarzy w docelowym wideo. W rozprawie rozpatrywane są dwuwymiarowe obrazy twarzy i dlatego należało użyć metodę automatycznego ich wyodrębniania. Doktorant użył popularnej metody histogramu zorientowanych gradientów (HOG). Do określenia prawdziwości obrazu stworzył autorską procedurę polegającą na wykryciu punktów orientacyjnych twarzy, użyciu transformaty CWT, a następnie, tak jak poprzednio, zastosowanie jej wyników w postaci obrazów dwuwymiarowych jako danych wejściowych dla sieci splotowych. Ponieważ Autor używał ośmiu sieci splotowych trenowanych na zbiorze ImageNet, sieci te przyjmowały tensor o trzecim wymiarze zgodnym z kanałami RGB. Dlatego, mając te trzy kanały do dyspozycji, przetestował różne kombinacje obrazów cech – w różnych skalach oraz dla reprezentacji modułów i kątowych.

Dalej następuje podsumowanie pracy oraz bibliografia składająca się z 96 pozycji.

3. Uwagi krytyczne

W pracy algorytmy klasyfikacji zostały nazwane modelami płytkimi. Nazwa „model płytki” być może powinna być używana tylko dla określenia sieci neuronowej (MLP) dla odróżnienia jej od głębokiej.

Działanie części użytych klasyfikatorów jest mocno zależne od różnych parametrów. Np. dla klasyfikatora k-NN jest to liczba sąsiadów, a dla MLP m.in. liczba warstw i neuronów. Czy wiemy jakie przyjęto wartości parametrów i dlaczego takie?

Dlaczego w rozdziale 3 i 4 użyto akurat sześciu najlepszych klasyfikatorów?

Sieci splotowe swoją popularność zawdzięczają możliwości pominięcia algorytmów służących do ekstrakcji cech, gdyż zazwyczaj po odpowiednim uczeniu robią to lepiej niż tradycyjne algorytmy ekstrakcji cech. Dlaczego nie użyto sieci splotowych jednowymiarowych (CNN 1D) lub rekurencyjnych LSTM czy GRU z warstwami splotowymi wprost do sygnału EKG lub z akcelerometrów łożyska?

Autor pominął cały obszar literatury dotyczący One-Class Classifier (OCC), czyli klasyfikatora jednej klasy, używanego szczególnie do wykrywania anomalii w zbiorze danych, zazwyczaj gdy anomalia stanowi niewielki odsetek całego zbioru danych. Jest on trenowany na jednej, głównej klasie danych (klasie normalnej), a następnie jest używany do wykrywania danych odstających (anomalii) spoza tej klasy.

Zmienne w tekście czasami nie są pisane kursywą, np. „indeks dolny d”, str. 41

4. Ocena rozprawy

W ramach rozprawy doktorskiej Doktorant zaproponował oryginalne rozwiązanie związane z wykrywaniem anomalii z wykorzystaniem transformacji falkowej.

Rozprawa doktorska uwidacznia ogólną wiedzę teoretyczną i praktyczną mgr inż. Macieja Gołgowskiego. Mgr inż. Gołgowski opublikował trzy prace naukowe, w czasopiśmie „Przegląd Elektrotechniczny” oraz w materiałach konferencji IEEE. Zaprezentowany materiał pokazuje, że Doktorant zrealizował cel pracy. Rozprawa doktorska wykazuje umiejętność samodzielnego prowadzenia pracy naukowej mgr inż. Macieja Gołgowskiego. Rozprawa doktorska stanowi oryginalne rozwiązanie problemu naukowego. Zaproponowane metody mają duże znaczenie aplikacyjne dla nauk technicznych i przemysłu.

5. Wnioski końcowe recenzji

Podsumowując recenzję stwierdzam, że Pan mgr inż. Maciej Gołgowski w rozprawie doktorskiej „Wybrane metody uczenia maszynowego w zadaniach wykrywania anomalii procesów” zrealizował cel rozprawy. Zaprezentowane rezultaty stanowią oryginalny wkład Autora w rozwój dyscypliny Informatyka Techniczna i Telekomunikacja. Pan Maciej Gołgowski wykazał się umiejętnością samodzielnej pracy badawczej, znajomością literatury światowej i wiedzą w zakresie uczenia maszynowego. Recenzowana praca spełnia wymagania ustawy o tytule i stopniach naukowych w dyscyplinie naukowej Informatyka Techniczna i Telekomunikacja. Wnoszę o jej przyjęcie i dopuszczenie do dalszych etapów postępowania doktorskiego.

Częstochowa, dn. 4 września 2023 r.

prof. dr hab. inż. Rafał Scherer
Katedra Inteligentnych Systemów Informatycznych
Wydział Inżynierii Mechanicznej i Informatyki
Politechnika Częstochowska
al. Armii Krajowej 36
42-200 Częstochowa

Recenzja

rozprawy doktorskiej mgra inż. Macieja Gołgowskiego, pt.: Wybrane metody uczenia maszynowego w zadaniach wykrywania anomalii procesów.

Niniejszą recenzję opracowano na wniosek Rady Dyscypliny Naukowej Informatyka Techniczna i Telekomunikacja Wojskowej Akademii Technicznej im. Jarosława Dąbrowskiego. Promotorem jest prof. dr hab. inż. Stanisław Osowski.

1. Charakterystyka tematu, celu i tezy badawczej rozprawy

Wykrywanie anomalii jest ważnym narzędziem w wielu dziedzinach życia, zarówno w nauce, jak i technice i biznesie. Może być wykorzystane w cyberbezpieczeństwie, monitorowaniu procesów przemysłowych, medycynie, finansach, sieciach społecznościowych, monitorowaniu środowiska naturalnego itd. W rozprawie występują przykłady monitorowania maszyn, diagnostyki medycznej oraz wykrywania prób manipulacji informacjami. Wykrywanie anomalii jest istotnym narzędziem do identyfikacji nieprawidłowości, które mogą mieć negatywne skutki w różnych dziedzinach życia i gospodarki.

2. Zawartość rozprawy

Recenzowana praca mgra inż. Macieja Gołgowskiego składa się ze streszczenia, spisu treści, sześciu rozdziałów oraz bibliografii. Dokument liczy 104 strony.

Pierwszy rozdział jest krótkim wprowadzeniem do tematyki. Autor definiuje pojęcie anomalii procesu, istotę detekcji anomalii oraz omawia problemy związane ze stosowaniem metod klasyfikacji do wykrywania anomalii takie jak częste niezbalansowanie danych dotyczących anomalii, trudności w definiowanie przebiegów normalnych i anormalnych, czy określeniu

zakresu zmienności przebiegów normalnych. Metody wykrywania anomalii podzielono na odległościowe oraz bazujące na gęstości rozkładu. Podano cel pracy, którym jest stworzenie nowych metod wykrywania anomalii procesów głównie z wykorzystaniem transformacji falkowych ciągłych i dyskretnych do generacji cech i użycie różnych klasyfikatorów do wykrywania anomalii. Rozdział pierwszy kończy się przeglądem zawartości rozprawy.

Rozdział drugi prezentuje metody uczenia maszynowego stosowane w badaniach. Omówiono transformację falkową ciągłą oraz dyskretną. Autor przybliżył klasyfikatory używane w eksperymentach przeprowadzonych w dalszych rozdziałach, a mianowicie: losowy las drzew decyzyjnych, zespół klasyfikatorów gradient boosting, klasyfikator SVM, klasyfikator k-NN, klasyfikator oparty na procesie gaussowskim, sieć wielowarstwowy perceptron nieliniowy oraz naiwny klasyfikator Bayesa. Na końcu omówione zostały dokładniej sieci splotowe używane do analizy sygnałów, głównie obrazów. Podano przykład struktury AlexNet oraz wymieniono szereg późniejszych popularnych modeli CNN dostępnych w literaturze.

Rozdział 3 omawia wykrywanie anomalii w sygnałach EKG. Zaprezentowano krótki przegląd literatury dotyczącej wykrywania analizy EKG przy pomocy metod uczenia maszynowego. Omówiono sam sygnał EKG z pięcioma podstawowymi załamkami. Podkreślono dlaczego transformacja falkowa nadaje się dobrze do analizy sygnałów EKG przez jego nietypową charakterystykę. Do badań zastosowano zbiory danych pochodzące ze strony <https://physionet.org/> ze 162 nagraniami sygnału EKG. Próbkę były podzielone na trzy grupy: arytmie, niewydolność serca oraz pracę normalną. Sygnały były próbkowane z częstotliwością 128 herców. Doktorant podzielił dane w stosunku 70 do 30 na uczące i testujące. Przybliżono sposoby ekstrakcji cech za pomocą z wykorzystaniem szybkiej transformacji Fouriera, algorytmu Pana-Tompkinsa, oraz z zastosowaniem dyskretnej dekompozycji falkowej (DWT). W wyniku DWT uzyskuje się 78 cech (13 miar statystycznych dla sześciu sygnałów). Automatycznie dobrane cechy sygnału zostały poddane analizie zgodności chi-kwadrat. Wybrane cechy zostały użyte jako wektor wejściowy dla ośmiu popularnych klasyfikatorów. Eksperymenty przeprowadzono na zestawach 12, 24, 48 oraz 78 cech.

Autor wykonał eksperymenty dla wszystkich kombinacji klasyfikatorów i zestawów cech pokazujące, że najlepiej zachowywał się zestaw 24 cech i klasyfikator random forest. Dla tego zestawu cech, z sześciu najlepiej działających klasyfikatorów Autor stworzył zespół oparty na głosowaniu większościowym, co dalej poprawiło jakość klasyfikacji.

Ciągła transformacja falkowa pozwoliła wyekstrahować cechy w formie obrazu, który mógł być analizowany przez standardowe sieci splotowe 2D używane do obrazów. Obrazy cech zostały zmniejszone do standardowych rozdzielczości używanych przez obecne sieci CNN. W badaniach użyto sieć o trzech warstwach splotowych z funkcją ReLU i funkcją max pooling. Meta parametry sieci splotowej zostały wybrane eksperymentalnie, natomiast nie podano przykładowych zależności jak zmieniała się dokładność klasyfikacji w zależności od meta parametrów sieci. Takie podejście polegające na analizie bitmapy cech jak zwykłego obrazu nie dało dobrych wyników. I tutaj Autor podaje możliwe powody: dużą kompresję wejściowego obrazu cech oraz małą liczebność zbiorów danych.

W dalszych badaniach zostały użyte gotowe popularne sieci splotowe dostępne w sieci Internet, nauczone klasyfikacji 1000 klas obiektów wizualnych, czyli zbioru ImageNet. Zmieniono oczywiście liczbę wyjść, dostosowując struktury do rozważanego problemu. Uczono jedynie warstwy w pełni połączone odpowiedzialne za klasyfikację. Ośmiem takich architektur CNN po nauczeniu zadania wykrywania anomalii połączono w zespół, którego wyjście ustala się przez głosowanie większościowe. Uzyskane wyniki są porównywalne z najlepszymi wynikami uzyskanymi przez klasyfikatory tradycyjne. Natomiast, odbyło się to najprawdopodobniej za cenę bardzo dużej złożoności obliczeniowej takiego zespołu.

Rozdział 4 poświęcony jest wykrywaniu uszkodzeń łożysk tocznych poprzez analizę sygnałów pochodzących z czujników akcelerometrycznych. Zostały użyte dane pochodzące z serwisu Mendeley Data, zawierające cztery rodzaje uszkodzeń i stan normalny. Autor omówił problemy z wykorzystaniem podejścia opartego o transformację Fouriera, oraz dlaczego w tym przypadku transformacja falkowa powinna lepiej sprawdzić się przy analizie takiego procesu. Ogólnie podejście w tym rozdziale jest podobne jak w przypadku analizy sygnałów EKG, to znaczy tworzone są cechy z zastosowaniem DWT oraz CWT. Cechy dyskretne tworzone są automatycznie i poddane analizie testem chi-kwadrat w celu wyliczenia ważności poszczególnych cech. Wektory takich cech były danymi wejściowymi do sześciu popularnych klasyfikatorów oraz na ich bazie stworzono zespół oparty o głosowanie większościowe. W następnym kroku, podobnie jak poprzednio, zastosowano sieci splotowe do analizy obrazu z danymi wejściowymi w postaci obrazów powstałych w wyniku CWT. I znowu, początkowo użyto sieci splotowej tworzonej (uczonej) od podstaw, a następnie użyto metody transfer learning z użyciem ośmiu popularnych sieci splotowych wstępnie uczonych na zbiorze ImageNet.

Rozdział 5 dotyczy wykrywania obrazów wygenerowanych i zmanipulowanych przez systemy uczące się. Opisano pokrótce sieci GAN służące do tworzenia takich obrazów. W badaniach użyto zbioru danych FaceForensics++. W zbiorze danych występowały materiały tworzone przez metodę FaceSwap, gdzie sieć przenosiła obraz wykryty jako twarz z wideo wejściowego do wideo wyjściowego, przez metodę DeepFake, która używa autoenkodera do tworzenia syntetycznego obrazu, oraz metody Face2Face, która zmienia ekspresję twarzy w docelowym wideo. W rozprawie rozpatrywane są dwuwymiarowe obrazy twarzy i dlatego należało użyć metodę automatycznego ich wyodrębniania. Doktorant użył popularnej metody histogramu zorientowanych gradientów (HOG). Do określenia prawdziwości obrazu stworzył autorską procedurę polegającą na wykryciu punktów orientacyjnych twarzy, użyciu transformaty CWT, a następnie, tak jak poprzednio, zastosowanie jej wyników w postaci obrazów dwuwymiarowych jako danych wejściowych dla sieci splotowych. Ponieważ Autor używał ośmiu sieci splotowych trenowanych na zbiorze ImageNet, sieci te przyjmowały tensor o trzecim wymiarze zgodnym z kanałami RGB. Dlatego, mając te trzy kanały do dyspozycji, przetestował różne kombinacje obrazów cech – w różnych skalach oraz dla reprezentacji modułów i kątowych.

Dalej następuje podsumowanie pracy oraz bibliografia składająca się z 96 pozycji.

3. Uwagi krytyczne

W pracy algorytmy klasyfikacji zostały nazwane modelami płytkimi. Nazwa „model płytki” być może powinna być używana tylko dla określenia sieci neuronowej (MLP) dla odróżnienia jej od głębokiej.

Działanie części użytych klasyfikatorów jest mocno zależne od różnych parametrów. Np. dla klasyfikatora k-NN jest to liczba sąsiadów, a dla MLP m.in. liczba warstw i neuronów. Czy wiemy jakie przyjęto wartości parametrów i dlaczego takie?

Dlaczego w rozdziale 3 i 4 użyto akurat sześciu najlepszych klasyfikatorów?

Sieci splotowe swoją popularność zawdzięczają możliwości pominięcia algorytmów służących do ekstrakcji cech, gdyż zazwyczaj po odpowiednim uczeniu robią to lepiej niż tradycyjne algorytmy ekstrakcji cech. Dlaczego nie użyto sieci splotowych jednowymiarowych (CNN 1D) lub rekurencyjnych LSTM czy GRU z warstwami splotowymi wprost do sygnału EKG lub z akcelerometrów łożyska?

Autor pominął cały obszar literatury dotyczący One-Class Classifier (OCC), czyli klasyfikatora jednej klasy, używanego szczególnie do wykrywania anomalii w zbiorze danych, zazwyczaj gdy anomalia stanowi niewielki odsetek całego zbioru danych. Jest on trenowany na jednej, głównej klasie danych (klasie normalnej), a następnie jest używany do wykrywania danych odstających (anomalii) spoza tej klasy.

Zmienne w tekście czasami nie są pisane kursywą, np. „indeks dolny d”, str. 41

4. Ocena rozprawy

W ramach rozprawy doktorskiej Doktorant zaproponował oryginalne rozwiązanie związane z wykrywaniem anomalii z wykorzystaniem transformacji falkowej.

Rozprawa doktorska uwidacznia ogólną wiedzę teoretyczną i praktyczną mgra inż. Macieja Gołgowskiego. Mgr inż. Gołgowski opublikował trzy prace naukowe, w czasopiśmie „Przegląd Elektrotechniczny” oraz w materiałach konferencji IEEE. Zaprezentowany materiał pokazuje, że Doktorant zrealizował cel pracy. Rozprawa doktorska wykazuje umiejętność samodzielnego prowadzenia pracy naukowej mgra inż. Macieja Gołgowskiego. Rozprawa doktorska stanowi oryginalne rozwiązanie problemu naukowego. Zaproponowane metody mają duże znaczenie aplikacyjne dla nauk technicznych i przemysłu.

5. Wnioski końcowe recenzji

Podsumowując recenzję stwierdzam, że Pan mgr inż. Maciej Gołgowski w rozprawie doktorskiej „Wybrane metody uczenia maszynowego w zadaniach wykrywania anomalii procesów” zrealizował cel rozprawy. Zaprezentowane rezultaty stanowią oryginalny wkład Autora w rozwój dyscypliny Informatyka Techniczna i Telekomunikacja. Pan Maciej Gołgowski wykazał się umiejętnością samodzielnej pracy badawczej, znajomością literatury światowej i wiedzą w zakresie uczenia maszynowego. Recenzowana praca spełnia wymagania ustawy o tytule i stopniach naukowych w dyscyplinie naukowej Informatyka Techniczna i Telekomunikacja. Wnoszę o jej przyjęcie i dopuszczenie do dalszych etapów postępowania doktorskiego.

