

Autoreferat

1. Imiona i Nazwisko: **Jarosław Kurek**.

2. Posiadane dyplomy, stopnie naukowe – z podaniem nazwy, miejsca i roku ich uzyskania.

- magister inżynier – kierunek informatyka, Wydział Elektryczny, Politechnika Warszawska, 2004, praca magisterska pod tytułem „**Analiza skupień za pomocą metod neuronowych i statystycznych**”, praca oceniona z wyróżnieniem.
- doktor inżynier nauk technicznych w dyscyplinie elektrotechnika, Wydział Elektryczny, Politechnika Warszawska, 2008, rozprawa doktorska pod tytułem: „**Diagnostyka uszkodzeń prętów klatki maszyny asynchronicznej z zastosowaniem sieci neuronowej**”.

3. Informacje o dotychczasowym zatrudnieniu w jednostkach naukowych/artystycznych.

- 2008–obecnie – pracownik naukowo-dydaktyczny, kierownik Katedry Zastosowań Informatyki, aktualnie na stanowisku adiunkta od 1 stycznia 2017 roku, Katedra Zastosowań Informatyki, Wydział Zastosowań Informatyki i Matematyki, Szkoła Główna Gospodarstwa Wiejskiego.

4. Wskazanie osiągnięcia* wynikającego z art. 16 ust. 2 ustawy z dnia 14 marca 2003 r. o stopniach naukowych i tytule naukowym oraz o stopniach i tytule w zakresie sztuki (Dz. U. nr 65, poz. 595 ze zm.):

- jednotematyczny cykl 14 publikacji w porządku **chronologicznym** pod tytułem:

Metody sztucznej inteligencji w rozwiązywaniu zagadnień klasyfikacji w wybranych problemach diagnostycznych

a) (autor/autorzy, tytuł/tytuły publikacji, nazwa wydawnictwa, rok wydania),

1. **JAROSŁAW KUREK**, Stanisław Osowski, „Support vector machine for fault diagnosis of the broken rotor bars of squirrel-cage induction motor”, **Neural Computing and Applications**, vol. 19, No. 4, pp. 557-564, 2010.
2. **JAROSŁAW KUREK**, Stanisław Osowski, „Diagnostic feature selection for efficient recognition of different faults of rotor bars in the induction machine”, **Przegląd Elektrotechniczny**, vol. 86, pp. 121-123, 2010.
3. **JAROSŁAW KUREK**, Bartosz Świdorski, Stanisław Osowski, „Assessment of financial condition of companies using neural networks”, **Przegląd Elektrotechniczny**, vol. 87, pp. 88-91, 2011.

4. Bartosz Świderski, **JAROSŁAW KUREK**, Stanisław Osowski, „Multistage classification by using logistic regression and neural networks for assessment of financial condition of company”, **Decision Support Systems**, vol. 52, pp. 539-547, 2012.
5. **JAROSŁAW KUREK**, Michał Kruk, Stanisław Osowski, Paweł Hoser, Grzegorz Wieczorek, Albina Jegorowa, Jarosław Górski, Jacek Wilkowski, Katarzyna Śmietańska, Joanna Kossakowska, „Developing automatic recognition system of drill wear in standard laminated chipboard drilling process”, **Bulletin of the Polish Academy of Sciences-Technical Sciences**, vol. 64 No. 3, pp. 633-640, 2016.
6. Michał Kruk, Albina Jegorowa, **JAROSŁAW KUREK**, Stanisław Osowski, Jarosław Górski, „Automatic recognition of drill condition on the basis of images of drilled holes”, **Proceedings of 17th International Conference Computational Problems of Electrical Engineering**, pp. 1-4, 2016.
7. Michał Kruk, **JAROSŁAW KUREK**, Stanisław Osowski, Robert Koktysz, Bartosz Świderski, Tomasz Markiewicz, „Ensemble of classifiers and wavelet transformation for improved recognition of Fuhrman grading in clear-cell renal carcinoma”, **Biocybernetics and Biomedical Engineering**, vol. 37, pp. 357-364, 2017.
8. Bartosz Świderski, **JAROSŁAW KUREK**, Stanisław Osowski, Michał Kruk, Walid Barhoumi, „Deep Learning and Non-Negative Matrix Factorization in Recognition of Mammograms”, **8th International Conference on Graphic and Image Processing, Proceedings of SPIE**, vol. 10225, 2017.
9. **JAROSŁAW KUREK**, Bartosz Świderski, Albina Jegorowa, Michał Kruk, Stanisław Osowski, „Deep learning in assessment of drill condition on the basis of images of drilled holes”, **8th International Conference on Graphic and Image Processing, Proceedings of SPIE**, vol. 10225, 2017.
10. **JAROSŁAW KUREK**, Bartosz Świderski, Stanisław Osowski, Michał Kruk, Albina Jegorowa, „Transfer learning in recognition of drill wear using convolutional neural network”, **Proceedings of 18th International Conference Computational Problems of Electrical Engineering**, pp. 1-4, 2017.
11. Sami Dhahbi, Walid Barhoumi, **JAROSŁAW KUREK**, Bartosz Świderski, Michał Kruk, Ezzeddine Zagrouba, „False-positive reduction in computer-aided mass detection using mammographic texture analysis and classification”, **Computer Methods and Programs in Biomedicine**, vol. 160, pp. 75-83, 2018.
12. **JAROSŁAW KUREK**, Bartosz Świderski, Stanisław Osowski, Michał Kruk, Walid Barhoumi, „Deep learning versus classical neural approach to mammogram recognition”, **Bulletin of the Polish Academy of Sciences – Technical Sciences**, vol. 66 No. 6, pp. 831-840, 2018.
13. **JAROSŁAW KUREK**, Grzegorz Wieczorek, Bartosz Świderski, Michał Kruk, Albina Jegorowa, Jarosław Górski, „Automatic Identification of Drill Condition During Drilling Process in Standard Laminated Chipboard with the Use of Long Short-Term

Memory (LSTM)", **Proceedings of 19th International Conference Computational Problems of Electrical Engineering**, pp. 1–4, 2018.

14. **JAROSŁAW KUREK**, „Hybrid approach towards the assessment of a drill condition using deep learning and the Support Vector Machine”, **22nd International Computer Science and Engineering Conference**, Thailand, 2018.


b) omówienie celu naukowego/artystycznego ww. pracy/prac i osiągniętych wyników wraz z omówieniem ich ewentualnego wykorzystania.

Wstęp



Tematyka moich prac badawczych dotyczy głównie opracowania skutecznych metod sztucznej inteligencji do rozwiązywania zagadnień klasyfikacji w wybranych problemach diagnostycznych. Podejmowane zagadnienia badawcze to zarówno zastosowanie dobrze znanych metod sztucznej inteligencji w zagadnieniach aplikacyjnych, jak i opracowanie nowych i zmodyfikowanych algorytmów sztucznej inteligencji zwiększających skuteczność działania w konkretnych zastosowaniach. Wszystkie prace badawcze mają związek z zagadnieniami klasyfikacji i dotyczą szerokiej gamy problemów diagnostycznych.

Aby usytuować opisywaną problematykę jednotematycznego cyklu publikacji w nurcie dyscypliny, można odwołać się do Encyklopedii PWN, w której sztuczna inteligencja określona jest jako: „...w nurcie teoretycznym sztuczna inteligencja łączy zagadnienia z różnych dziedzin. W kierunku doświadczalnym stanowi dział informatyki, w którym docelowo tworzy się programy komputerowe symulujące inteligentne zachowania człowieka...”¹. Wszystkie prace naukowe wchodzące w skład jednotematycznego cyklu publikacji dotyczą metod sztucznej inteligencji, a zatem należą do dyscypliny informatyka.

Aby zobrazować podejmowaną tematykę i powiązanie powyższych publikacji, zostały one przedstawione w postaci poniższych schematów:



¹ <https://encyklopedia.pwn.pl/haslo/sztuczna-inteligencja;3983490.html>, dostęp 03-02-2019.



Wśród osiągnięć naukowych dotyczących metod sztucznej inteligencji w kontekście klasyfikacji można wyróżnić:

- 1) Opracowanie nowych metod generacji deskryptorów numerycznych analizowanego procesu ukierunkowanych na zagadnienia klasyfikacji w wybranych problemach diagnostycznych.
- 2) Opracowanie nowatorskich deskryptorów numerycznych obrazów polegających na optymalnej konwersji obrazu do postaci wektorowej stanowiącej podstawę generacji istotnych cech diagnostycznych.

- 3) Opracowanie metody automatycznego pozyskania deskryptorów numerycznych w wybranych problemach diagnostycznych z użyciem uczenia głębokiego.
- 4) Opracowanie nowych metod selekcji cech diagnostycznych usprawniających proces klasyfikacji.
- 5) Zaproponowanie skutecznej architektury wykorzystującej uczenie maszynowe oraz uczenie głębokie w rozwiązaniu wybranych zagadnień diagnostycznych oraz przeprowadzenie porównania różnego rodzaju podejść w praktycznych przykładach eksploracji danych.
- 6) Opracowanie nowych metod fuzji klasyfikatorów pracujących w zespole pozwalających na polepszenie dokładności klasyfikacji w wybranych zagadnieniach diagnostycznych.
- 7) Opracowanie nienadzorowanych metod ekstrakcji informacji pod kątem dalszego procesu modelowania, np. NMF-non-negative matrix factorization, dla wzbogacenia informacji o analizowanych obrazach.
- 8) Opracowanie metod sztucznego rozszerzania kanałów informacyjnych w obrazach skali szarości, do zwiększenia dokładności klasyfikacji przy użyciu sieci głębokiej CNN.
- 9) Opracowanie nowych metod rozwiązania problemu małej liczby próbek uczących w sieci CNN uczenia głębokiego.
- 10) Opracowanie nowatorskiego podejścia wyznaczania klasy w postaci dynamicznego określenia progu klasyfikacji podczas procesu uczenia.

Wśród zagadnień aplikacyjnych, w których zastosowano metody sztucznej inteligencji w wybranych zagadnieniach diagnostycznych można wyróżnić aplikacje typowo inżynierskie, biomedyczne, jak i czysto ekonomiczne. Należą do nich między innymi:

1. Zastosowanie metod sztucznej inteligencji do diagnostyki stanu prętów klatki wirnika silnika indukcyjnego.
2. Zastosowanie metod sztucznej inteligencji do diagnostyki stanu wiertła w trybie online na podstawie zarejestrowanych sygnałów z sensorów.
3. Zastosowanie metod sztucznej inteligencji do diagnostyki stanu wiertła w trybie online na podstawie zarejestrowanych zdjęć otworów po procesie wiercenia.
4. Zastosowanie metod sztucznej inteligencji do rozpoznawania czerniaka na podstawie obrazów dermatoskopowych zmian skórnych.
5. Zastosowanie metod sztucznej inteligencji do rozpoznawania jasnokomórkowego raka nerki.
6. Zastosowanie metod sztucznej inteligencji do rozpoznawania raka piersi na podstawie zdjęć mammograficznych.
7. Zastosowanie metod sztucznej inteligencji do oceny ryzyka kredytowego przedsiębiorstw na podstawie raportów kredytowych.

Opublikowane wyniki układają się w cykl 8 prac opublikowanych w czasopiśmie znajdujących się w bazie JCR oraz 6 prac z listy B i dotyczą zastosowania metod sztucznej inteligencji w rozwiązywaniu zagadnień klasyfikacji w wybranych problemach diagnostycznych.

- Artykuły [1,2] prezentują nowatorską propozycję podejścia do diagnostyki stanu prętów klatki wirnika silnika indukcyjnego. Pierwsza publikacja przedstawia skuteczną próbę klasyfikacji dwóch stanów prętów klatki wirnika (stan bez uszkodzenia oraz z uszkodzeniem prętów). Do tego celu zastosowano specjalnie zaproponowane cechy diagnostyczne. Klasyfikatorem użytym do tego celu była jednoklasowa sieć SVM. Druga praca dotyczy próby rozpoznania 10 różnych klas stanów prętów klatki wirnika

- silnika indukcyjnego dla fizycznego modelu silnika, w którym symuluje się uszkodzenie prętów silnika indukcyjnego w postaci poluzowania połączeń prętów silnika indukcyjnego. W pracy zaprezentowano nowatorskie metody selekcji cech, których wynikiem są zbiory deskryptorów numerycznych najlepiej różnicujących 10 różnych stanów prętów klatki wirnika. Należy wspomnieć, że w eksperymencie brały udział próbki pozyskane z realnych dużych silników indukcyjnych z takich lokalizacji, jak laboratorium Politechniki Warszawskiej, Metro Warszawskie, zakłady remontowe przedsiębiorstwa Tramwaje Warszawskie, elektrownia wodna Dębe.
- W artykułach [3,4] opracowano szereg deskryptorów numerycznych do automatycznej klasyfikacji kondycji finansowej przedsiębiorstw do jednej z 5 klas (excellent, good, satisfactory, passable, poor). Dane pochodziły z rzeczywistej bazy raportów kredytowych jednej lokalnej oraz dwóch międzynarodowych agencji kredytowych. Celem pracy było komputerowe wspomaganie analityków finansowych podczas opracowywania raportu kredytowego. Metody sztucznej inteligencji pozwoliły na zaklasyfikowanie analizowanej firmy do jednej z pięciu klas ryzyka niewypłacalności (ang. insolvency risk). Dodatkowo w artykule [4] zaproponowano nowatorskie podejście do reprezentacji cech diagnostycznych w postaci uciągłonej – wagi dowodu WoE (ang. weight of evidence – WoE), które sprawdza się w przypadku, gdy zmienna ma charakter gradacyjny. Nowatorską metodą sztucznej inteligencji była także zaproponowana fuzja 7 modeli klasyfikatorów, które pracowały w zespole i razem podejmowały ostateczną decyzję klasyfikacyjną.
 - Artykuły [5,6] odnoszą się do opracowania i implementacji automatycznego systemu rozpoznawania stanu wiertła podczas wiercenia w płycie laminowanej. Klasyfikacja dotyczyła dwóch klas: stanu, gdzie wiertło nadaje się jeszcze do pracy na linii produkcyjnej oraz stanu stępienia, który wymaga już wymiany wiertła na nowe. W publikacji [5] zaproponowano nowe deskryptory numeryczne, na podstawie których dokonano skutecznej próby klasyfikacji z użyciem sieci SVM, lasów losowych oraz zespołu drzew decyzyjnych. Dane do analizy pozyskano dzięki współpracy z Wydziałem Technologii Drewna SGGW. Pozyskano sygnały czasowe zarejestrowane z 4 sensorów umieszczonych na stanowisku pomiarowym. Natomiast w pracy [6] zastosowano inną metodę budowy automatycznego systemu diagnostycznego wiertła w trybie online (bez wyłączania urządzenia), w porównaniu do pracy [5], a mianowicie wykorzystano obrazy otworów uzyskanych tuż po procesie wiercenia. Za pomocą przymocowanego aparatu fotograficznego wykonano 900 zdjęć otworów, na podstawie których wygenerowano cechy diagnostyczne, które wykorzystano następnie w procesie klasyfikacji stanu wiertła.
 - Publikacja [7] odnosi się do opracowania i implementacji systemu automatycznego rozpoznawania 4 stopni w skali Fuhrmana w diagnostyce raka jasnokomórkowego nerki. Dane, na których oparto klasyfikację pochodziły ze współpracy z Zakładem Patomorfologii Wojskowego Instytutu Medycznego w Warszawie. Wygenerowano dedykowane cechy diagnostyczne pozyskane z danych obrazowych. Dodatkowo zaproponowano metody selekcji cech diagnostycznych do uzyskania zbiorów cech najlepiej różnicujących 4 stopnie w skali Fuhrmana. Istotnym elementem rozwiązanego zagadnienia są dwie fuzje klasyfikatorów pracujących w zespole.
 - Prace [8,9,10,12,13,14] dotyczą nowych metod sztucznej inteligencji użytych w zagadnieniu klasyfikacji za pomocą różnych algorytmów uczenia głębokiego, takich jak sieci CNN (ang. convolutional neural network), LSTM (ang. long short-term memory). Dodatkowo porównano skuteczność klasyfikacji uczenia maszynowego oraz

uczenia głębokiego. Zaproponowano także modyfikacje architektur z uwzględnieniem już wytrenowanych sieci CNN – tzw. uczenie transferowe (np. transfer learning). Wszystkie te modyfikacje pozwoliły na poprawienie wyników dokładności klasyfikacji podejmowanych problemach.

- Prace [8,11] dotyczyły diagnostyki raka piersi na podstawie publicznie dostępnej bazy Digital Database for Screening Mammography (DDSM). W artykule [11] klasyfikacja została oparta na metodach uczenia maszynowego, natomiast w pracy [8] wykorzystano mechanizmy uczenia głębokiego w postaci sieci CNN.
- Publikacja [12] dotyczyła zaawansowanych porównań i dodatkowych analiz uczenia maszynowego oraz uczenia głębokiego w problemie diagnostyki raka piersi na podstawie obrazów mammograficznych.
- Artykuł [13] jest kontynuacją pracy [5] i dotyczył zwiększenia trudności problemu diagnostycznego w postaci zwiększenia liczby rozpoznawanych klas z dwóch do trzech. Istotnym elementem pogłębionego zagadnienia było wykorzystanie algorytmu uczenia głębokiego LSTM (ang. long short-term memory). Wyniki jednoznacznie wskazują, że algorytmy uczenia głębokiego mają większy potencjał klasyfikacyjny niż dotychczasowe uczenie maszynowe, jednak wymagają dużo większego zbioru danych niż klasyczne podejście.
- W Artykule [9] zastosowano nowoczesne metody sztucznej inteligencji w roli klasyfikatorów z użyciem sieci CNN uczenia głębokiego. W obu artykułach klasyfikacja polegała na diagnostyce stanu wiertła podczas procesu wiercenia, czyli przypisanie stanu wiertła do jednej z dwóch klas: stanu wiertła jeszcze ostrego oraz stanu wiertła zużytego (stępionego).
- Artykuł [14] dotyczy fuzji metod sztucznej inteligencji w formie integracji uczenia maszynowego i uczenia głębokiego użytych do diagnostyki stanu wiertła podczas procesu wiercenia w płycie laminowanej. Podejście hybrydowe polegało na ręcznej ekstrakcji deskryptorów numerycznych na podstawie danych zdjęć otworów po procesie wiercenia oraz na automatycznej ekstrakcji nowych cech diagnostycznych za pomocą sieci CNN uczenia głębokiego. Fuzja tych wszystkich cech pozwoliła na skuteczną klasyfikację stanu wiertła do jednej z trzech klas (zielona, żółta, czerwona). Klasa zielona dotyczy wiertła jeszcze ostrego, zdolnego do pracy, klasa żółta – wiertła o niepewnym stanie (wskazana manuala ocena) oraz klasa czerwona dotyczy wiertła stępionego, które powinno być już wykluczone z procesu produkcyjnego, aby nie ponosić większych kosztów produkcji.
- Prace [3,7] pokazują nowatorskie podejście w postaci fuzji wielu klasyfikatorów mogących mieć zastosowanie w wielu problemach diagnostycznych, zarówno obrazowych, finansowych, jak również zarejestrowanych sygnałów zmiennych w czasie.

Uzyskane osiągnięcia naukowe są efektem mojej aktywnej współpracy z:

1) krajowymi ośrodkami badawczymi:

- Centrum Onkologicznym w Warszawie,
- Zakładem Patomorfologii Wojskowego Instytutu Medycznego w Warszawie,
- Wydziałem Elektrycznym Politechniki Warszawskiej,


- Wydziałem Technologii Drewna Szkoły Głównej Gospodarstwa Wiejskiego w Warszawie,
- 2) międzynarodowymi ośrodkami badawczymi:
 - National Engineering School of Carthage, University UVT of Tunis (Tunis, Tunezja),
- 3) krajowymi agencjami kredytowymi:
 - P&A Credit Agency sp. z o.o. sp. komandytowa (Warszawa, Polska),
- 4) międzynarodowymi agencjami kredytowymi:
 - Dynamic Business Information Ltd. (Londyn, Wielka Brytania),
 - Dynamic Business Information (Asia Pacific) Sdn. Bhd. (Kuala Lumpur, Malezja).

1. Zastosowanie jednoklasowej sieci SVM (ang. Support Vector Machine) do diagnostyki stanu prętów klatki wirnika silnika indukcyjnego

Jedna z części pracy naukowej [1] przedstawia zastosowanie jednoklasowej sieci SVM (ang. single-class SVM) w zastosowaniu do budowy automatycznego systemu diagnostycznego rozpoznającego stan prętów klatki wirnika silnika indukcyjnego. Jest to specjalny rodzaj sieci SVM zaproponowany przez Schölkopf and Smola. Cechą charakterystyczną tego rodzaju sieci SVM jest wykorzystanie do procesu uczenia sieci wyłącznie danych należących do jednej klasy, reprezentujących tylko stan pracy silnika indukcyjnego bez uszkodzenia prętów klatki wirnika. Ze względu na niezmiernie trudne pozyskanie dużej liczby danych rzeczywistych uszkodzeń prętów klatki wirnika silnika indukcyjnego, podjęta została próba uczenia sieci wyłącznie na danych należących do jednej klasy, których liczba jest największa, czyli w tym przypadku stan maszyny indukcyjnej bez uszkodzenia wirnika silnika indukcyjnego.

Cechy diagnostyczne wyznaczone zostały w niedalekim sąsiedztwie ($\Delta f = \pm 0,01 f_s$) występowania dwóch częstotliwości poślizgowych, wokół pierwszej harmonicznej prądu stojana. Dwie częstotliwości poślizgowe wokół pierwszej harmonicznej prądu stojana można wyrazić wzorami: $f_{pl} = (1-2s)f_s$ i $f_{pu} = (1+2s)f_s$. Rysunek 1 pokazuje spektrum widma prądu stojana wokół częstotliwości poślizgowych w zależności od liczby uszkodzonych prętów klatki wirnika silnika indukcyjnego.

Janek lub



Rysunek 1. Przykłady spektrum widma prądu stojana wokół częstotliwości poślizgowych w zależności od uszkodzenia prętów klatki wirnika silnika indukcyjnego: a) stan bez uszkodzenia, b) 1 pręt uszkodzony, c) 3 pręty uszkodzone, d) 6 prętów uszkodzonych

Na podstawie poniższych wzorów wyznaczono dwie częstotliwości diagnostyczne x_1 i x_2 .

$$I(f_{pl}) = \max_f \{I(f_{pl} - 0.01f_s), I(f_{pl} + 0.01f_s)\}$$

$$I(f_{pu}) = \max_f \{I(f_{pu} - 0.01f_s), I(f_{pu} + 0.01f_s)\}$$

$$x_1 = I(f_{pl}) - \frac{I(f_{pl} - 0.01f_s) + I(f_{pl} + 0.01f_s)}{2}$$

$$x_2 = I(f_{pu}) - \frac{I(f_{pu} - 0.01f_s) + I(f_{pu} + 0.01f_s)}{2}$$

W eksperymentach numerycznych z użyciem jednoklasowej sieci SVM użyto danych stanu silnika bez uszkodzenia prętów klatki wirnika, pochodzących z 31 rzeczywistych silników. Tabela 1 przedstawia wyniki potwierdzające zasadność użycia przedstawionych cech diagnostycznych wyznaczonych na wyżej wymienionych relacjach.

Tabela 1. Względne błędy testowania sieci jednoklasowej SVM na wyznaczonych cechach diagnostycznych

Type of testing data	Mean error of testing	Standard deviation of errors
All data	0.93%	0.62%
Machines with healthy bars only	6.37%	4.22%
Machine with broken bars only	0	0

Osiągnięciem naukowym w tej publikacji było opracowanie skutecznego rozwiązania problemu diagnostyki dwóch stanów prętów klatki wirnika silnika indukcyjnego za pomocą metod sztucznej inteligencji. Dotyczy to zarówno opracowania skutecznych deskryptorów numerycznych do diagnostyki stanu prętów klatki wirnika silnika indukcyjnego, jak i doboru oraz implementacji odpowiedniego klasyfikatora do podejmowanego problemu. Ze względu na dysproporcje w liczbie zarejestrowanych sygnałów dla silników uszkodzonych i nieuszkodzonych (liczba uszkodzonych silników była znacznie mniejsza niż nieuszkodzonych) wykorzystano jednoklasową sieć SVM, której trenowanie odbywało się wyłącznie na próbkach pochodzących z jednej klasy (silników nieuszkodzonych). Różnica liczebności danych uczących w dwóch klasach była zbyt duża i mogła negatywnie wpłynąć na zdolności generalizacyjne klasyfikatora. Z uwagi na ten fakt osiągnięciem naukowym był taki dobór klasyfikatora oraz jego parametrów (w tym przypadku jednoklasowej sieci SVM) oraz jego implementacja, który pozwoliłby na skuteczną generalizację wiedzy tylko na podstawie danych pochodzących z silników nieuszkodzonych.

2. Dwuetapowa selekcja cech diagnostycznych w zastosowaniu do rozpoznania różnych uszkodzeń prętów maszyny indukcyjnej

W pracy [2] pogłębiono diagnostykę uszkodzeń prętów maszyny indukcyjnej przez zwiększenie liczby analizowanych klas z dwóch do dziesięciu. Do rozwiązania problemu klasyfikacji 10 stanów prętów maszyny indukcyjnej zastosowano dwuetapową selekcję cech do diagnostyki uszkodzenia prętów silnika indukcyjnego.

W pierwszym etapie selekcji cech zastosowano selekcję różnicową (ang. differential selection) polegającą na automatycznym wyborze harmonicznych prądu, napięcia i strumienia najlepiej różnicujących 10 klas stanu wirnika silnika indukcyjnego (1 klasa bez uszkodzenia prętów oraz 9 klas z różną konfiguracją uszkodzenia prętów). Zaproponowano dwie miary $d_1(f)$ i $d_2(f)$ do oceny wartości diagnostycznej pomiędzy dwiema zadanymi klasami danych (stan wirnika bez uszkodzenia prętów oraz z uszkodzeniem co najmniej jednego pręta).

Wartość diagnostyczną $d_1(f)$ harmonicznej o częstotliwości f dla rozróżnienia klasy x i y zdefiniowano następująco:

$$d_1(f) = \sum_{i=1}^n \sum_{j=1}^m (x_i(f) - y_j(f))$$

Natomiast drugą miarę $d_2(f)$ zdefiniowano następująco:

$$d_2(f) = \sum_{i=1}^n \sum_{j=1}^m \text{sign}(x_i(f) - y_j(f))$$

Największa wartość $d_1(f)$ oraz $d_2(f)$ oznacza, że dana częstotliwość f ma największy wpływ na rozróżnienie dwóch klas. Dla każdych kombinacji 10 klas (prądu, napięcia, strumienia) wyodrębniono 5 harmoniczných o największej wartości diagnostycznej, które przejdą do drugiego etapu selekcji cech diagnostycznych: wielokrokowej selekcji regresyjnej (ang. multistep regressive selection).

Drugi etap selekcji dotyczył zawężenia zbioru potencjalnych cech diagnostycznych (także zmniejszenie liczby cech skorelowanych), podnoszących dokładność klasyfikacji. W wyselekcjonowanym zbiorze cech za pomocą selekcji różnicowej można spodziewać się znacznego ich skorelowania wynikającego z bliskiego sąsiedztwa (efekt rozdzielczości). Cechy skorelowane mogą zdominować pozostałe i zmniejszyć efektywność działania całego zbioru. Do tego celu zastosowano wielokrokową selekcję regresyjną, która pozwala na zmniejszenie oryginalnego zestawu potencjalnych cech diagnostycznych do zbioru zredukowanego, pozbawionego cech najbardziej skorelowanych. Selekcja wielokrokowa polega na połączeniu ze sobą dwóch prostszych metod: selekcji postępującej oraz eliminacji wstecznej. W obliczeniach numerycznych przyjęto wartość poziomu istotności dla kryterium wejścia cechy do zbioru cech istotnych $\alpha_1=0,05$, natomiast dla kryterium wyjścia cechy ze zbioru cech istotnych wartość $\alpha_2=0,1$.

Wyniki przeprowadzonej selekcji cech przedstawiają tabela 2 oraz tabela 3.

Tabela 2. Wyniki liczby unikatowych harmoniczných najlepiej różnicujących 10 klas dla prądu, napięcia i strumienia po zastosowaniu pierwszego etapu selekcji cech dla dwóch wskaźników diagnostycznych $d_1(f)$ i $d_2(f)$

Ranking measure	Current	Voltage	Flux
$d_1(f)$	11	12	20
$d_2(f)$	33	35	34

Tabela 3. Wyniki liczby unikatowych harmoniczných najlepiej różnicujących 10 klas dla prądu, napięcia i strumienia po zastosowaniu drugiego etapu selekcji cech dla dwóch wskaźników diagnostycznych $d_1(f)$ i $d_2(f)$

Ranking measure	Current	Voltage	Flux
$d_1(f)$	4	4	8
$d_2(f)$	18	17	16

Po uzyskaniu docelowego, zawężonego zbioru cech diagnostycznych poddano je analizie diagnostycznej za pomocą sieci SVM (ang. Suport Vector Machine), w której zastosowano jądro gaussowskie (ang. gaussian kernel). Wyniki diagnostyki uszkodzenia prętów maszyny indukcyjnej za pomocą cech diagnostycznych dla prądu, napięcia i strumienia wału, wyodrębnionych za pomocą zaproponowanych wskaźników diagnostycznych, przedstawia tabela 4.

Jan K.

Tabela 4. Względne błędy uzyskane podczas rozpoznawania klas uszkodzeń prętów klatki wirnika silnika indukcyjnego

Ranking measure	Current features	Voltage features	Flux features
$d_1(f)$	0.26%	9.37%	0.87%
$d_2(f)$	1.35%	3.5%	1.78%

Osiągnięciem naukowym przedstawionym w tej publikacji było opracowanie skutecznej metodyki rozwiązania problemu diagnostycznego w postaci rozpoznawania różnych uszkodzeń prętów (10 klas) maszyny indukcyjnej za pomocą metod sztucznej inteligencji. Zaproponowano dwa nowe algorytmy generacji deskryptorów numerycznych, które następnie podano na wejście drugiego etapu selekcji cech, czyli wielokrokowej selekcji regresyjnej. Następnie ograniczony zbiór cech diagnostycznych został użyty jako wejście na wieloklasową sieć SVM. Należy przy tym zauważyć, że natywnie sieć SVM pracuje jako klasyfikator dwuklasowy, więc należało dokonać modyfikacji klasyfikatora do zastosowania go w problemie diagnostycznym wieloklasowym.

3. Usprawniony algorytm selekcji cech w zagadnieniu oceny kondycji finansowej przedsiębiorstw w postaci ratingu za pomocą wieloklasowej sieci SVM (ang. support vector machine) oraz rozmytej sieci k-NN (ang. k-nearest neighbors algorithm)

W pracy [3] wykorzystano wieloklasową realizację sieci SVM do oceny kondycji finansowej przedsiębiorstw w postaci klasyfikacji raportów kredytowych do jednej z 5 klas ratingu (przez ekspertów nazywane także ryzykiem niewypłacalności, ang. insolvency risk). Podejmowane w zagadnieniu klasy to: excellent (bez ryzyka), good, satisfactory, passable, poor (duże ryzyko niewypłacalności przedsiębiorstwa). Zaproponowano algorytm sztucznej inteligencji, który automatycznie klasyfikuje dane przedsiębiorstwo do jednej z pięciu istniejących klas ratingu. Na podstawie tej decyzji możliwe jest dalsze oszacowanie maksymalnego kredytu kupieckiego, dzięki któremu przedsiębiorstwo może uzyskać kredyt w banku lub ubezpieczyć transakcję międzynarodową.

Dane do obliczeń zostały pozyskane z 2 dużych korporacji międzynarodowych (Londyn i Kuala Lumpur) oraz jednej polskiej (Warszawa). W sumie baza danych składała się z 2217 rzeczywistych zanonimizowanych raportów kredytowych, na podstawie których zbudowano automatyczny system klasyfikujący przedsiębiorstwo do jednego z 5 klas ryzyka kredytowego – ratingu. Liczebność raportów kredytowych należących do poszczególnych klas zaprezentowano w tabeli 5.

Tabela 5. Liczebność raportów kredytowych w poszczególnych klasach ryzyka kredytowego – ratingu

Excellent	211
Good	800
Satisfactory	783
Passable	332
Poor	91
Total:	2217

Na podstawie analiz i konsultacji z analitykami finansowymi ręcznie oceniającymi kondycję finansową przedsiębiorstw (klasyfikacja przypadku do jednej z pięciu istniejących

klas), wygenerowano 37 potencjalnych cech diagnostycznych, które następnie przeszły do drugiej fazy selekcji cech. Przykładowe wygenerowane cechy diagnostyczne zostały przedstawione w tabeli 6.

Tabela 6. Przykładowe potencjalne cechy diagnostyczne z bazy raportów kredytowych

Consolidation class	Total Assets for the last year
Sales turnover for the last year	Current liabilities for the last year
Profit before tax for the last year	Total liabilities for the last year
Current Assets for the last year	Trend of sales turnover
Shareholders' equity	Trend of profit after tax
Phone connection	Trend of shareholders' equity
Fax connection	Age of company (in years)
Legal form class	Number of employees
Number of employees for group	Share capital (authorised or issued/paid-up)
Payment behaviour	Class of sales turnover
If profit after tax <0	Class of positive profit after tax
Sum of profit and equity (to cover losses)	Registry status

W celu określenia najbardziej istotnych cech diagnostycznych wykorzystano zmodyfikowaną sekwencyjną selekcję cech (ang. sequential feature selection). Modyfikacja polegała na zastąpieniu typowej regresji statystycznej, jako punktu wyznaczenia kryterium wejścia cechy do zbioru cech istotnych, przez klasyfikator użyty we właściwym procesie klasyfikacji (Fuzzy k-NN, SVM).

Sekwencyjna selekcja cech (ang. sequential feature selection) wybiera podzbiór cech diagnostycznych, dla których występuje najmniejszy błąd klasyfikacji. Jako kryterium błędu klasyfikacji wykorzystano wieloklasową sieć SVM oraz algorytm k-NN, których wyjście z sieci stanowiło podstawę stwierdzenia, czy dana cecha diagnostyczna powinna należeć do suboptymalnego zbioru cech diagnostycznych istotnych z punktu widzenia wysokiej skuteczności klasyfikacji. Dla każdego z analizowanych podzbiorów cech diagnostycznych zastosowano 10-krotną walidację krzyżową (ang. 10-fold cross-validation). Takie podejście do selekcji cech pozwala na użycie danego klasyfikatora już w procesie wyznaczania kryterium wejścia danej cechy do finalnego zbioru cech diagnostycznych biorących dalej udział we właściwym procesie klasyfikacji. Efektem zastosowania dedykowanego algorytmu selekcji cech jest wyznaczenie finalnego zbioru cech diagnostycznych, których użyto w procesie klasyfikacji.

W procesie klasyfikacji zastosowano wieloklasową sieć SVM oraz rozmytą wersję algorytmu k-najbliższych sąsiadów (ang. fuzzy k-nearest neighbours). Do obliczeń numerycznych w zagadnieniu decyzyjnym zastosowano 2217 unikatowych raportów kredytowych. Zbiór ten dzielono losowo na dwa zbiory zawierające dane do uczenia i testowania, odpowiednio w stosunku 80% i 20%. Wyniki klasyfikacji przedstawiono w tabeli 7 i 8.

Tabela 7. Wyniki klasyfikacji ryzyka kredytowego (ratingu) za pomocą rozmytej sieci k-NN

	Mean of error	Standard deviation of error
k=5	18.11%	2.2%
k=10	14.48%	2.0%
k=15	14.93%	2.4%
k=20	13.57%	2.1%
k=25	16.74%	2.3%
k=30	14.93%	2.0%

Tabela 8. Porównanie wyników klasyfikacji ryzyka kredytowego (ratingu) przedsiębiorstw za pomocą klasyfikatorów SVM oraz rozmytej wersji k-NN

	Mean of error	Standard deviation of error
SVM	19.2%	2.7%
Fuzzy k-NN (k=20)	13.57%	2.1%

Należy zaznaczyć, że błędy na poziomie 13% są w pełni akceptowalne przez ekspertów wszystkich trzech agencji kredytowych (jednej krajowej i dwóch międzynarodowych), którzy oceniają raporty kredytowe manualnie. Na podstawie analiz i konsultacji stwierdzono, że oszacowanie kondycji finansowej przedsiębiorstw jest na tyle trudne, że czasami ostateczna decyzja (klasyfikacja) balansuje na granicy dwóch klas i jest to w pełni akceptowalne. Dodatkowo należy zauważyć, że eksperci korzystają z dodatkowej wiedzy na temat aktualnej sytuacji geopolitycznej danego kraju, w której zarejestrowana jest analizowana firma oraz swojego wieloletniego doświadczenia, którego algorytmom sztucznej inteligencji ewidentnie na tym etapie często brakuje. Tego typu deskryptory nie zostały ujęte w diagnostyce, gdyż nie były dostępne w bazie raportów kredytowych, np. wskaźniki ryzyka geopolitycznego krajów (ang. country risk indicators). Bardzo dobre zastosowanie w tego typu badaniach ma rozmyta wersja k-NN, która oprócz właściwej klasyfikacji wskazuje stopień przynależności do danej klasy, dzięki czemu ekspert jest w stanie wziąć pod uwagę także stopień przynależności wyniku klasyfikacji do jednej z pięciu klas.

Osiągnięciem naukowym przedstawionym w tej publikacji było opracowanie skutecznej metodyki rozwiązania problemu diagnostycznego w postaci oszacowania kondycji finansowej przedsiębiorstw za pomocą metod sztucznej inteligencji. Oprócz generacji potencjalnych cech diagnostycznych na uwagę zasługuje fakt, że zaproponowano modyfikację algorytmu selekcji cech. Modyfikacja ta polegała na użyciu tego samego klasyfikatora zarówno do rozwiązywania docelowego problemu, jak i do algorytmu selekcji cech diagnostycznych jako kryterium wejścia danej cechy do zbioru finalnych deskryptorów numerycznych. Ponadto zaimplementowano rozmytą metodę k-NN, która określała stopień przynależności danej próbki testowanej do analizowanych klas. Podejście to było bardzo istotne z punktu widzenia ewentualnego wdrożenia zastosowanej metody w podejmowanym problemie diagnostycznym, gdyż nawet różni eksperci często nie byli zgodni co do klasyfikacji testowanej próbki. Rozmyta metoda pozwalała podać ekspertom nie tylko numer klasy, do której klasyfikator przypisał daną testowaną próbkę, ale też stopień przynależności do analizowanych klas, czyli w pewnym sensie stopień pewności decyzji klasyfikatora. W przypadku sieci SVM analogicznie możemy

mówić o odległości analizowanej próbki od marginesu separacji, czyli również stopnia pewności decyzji klasyfikacji.

4. Zastosowanie dwuetapowej fuzji klasyfikatorów usprawniających metody sztucznej inteligencji w zagadnieniu klasyfikacji kondycji finansowej przedsiębiorstw

Wybór konkretnej metody sztucznej inteligencji do zagadnień klasyfikacyjnych jest trudny, dlatego też warto zastanowić się nad zastosowaniem wielu klasyfikatorów jednocześnie pracujących w zespole (tzw. fuzja klasyfikatorów). Wszystkie stosowane typy klasyfikatorów pracujących w fuzji powinny być wybrane w taki sposób, aby były oparte na innej zasadzie działania. Każdy klasyfikator w danym czasie analizuje tę samą próbkę, czyli wejście na klasyfikator jest identyczne, natomiast wyniki mogą się różnić w zależności od typu klasyfikatora i ich parametrów. Na podstawie uzyskanych wyników z wielu zastosowanych typów klasyfikatorów algorytm fuzji powinien wygenerować jednoznaczną odpowiedź dla badanej próbki testującej. Okazuje się, że takie zastosowanie pozwala na otrzymanie rzetelnej odpowiedzi systemu diagnostycznego wspomaganego metodami sztucznej inteligencji oraz charakteryzuje się lepszymi wynikami klasyfikacji niż pojedyncze metody klasyfikacyjne.

Praca [4] dotyczy problemu klasyfikacji 5 klas ryzyka niewypłacalności o naturze gradacyjnej. Dokonano ekstrakcji cech diagnostycznych na podstawie rzeczywistych raportów kredytowych pozyskanych z trzech agencji kredytowych (jednej lokalnej i dwóch międzynarodowych).

Zaproponowano dwuetapowe podejście w postaci fuzji klasyfikatorów. Pierwszy etap polegał na opracowaniu siedmiu niezależnych modeli od M_1 do M_7 , które wskazywały przynależność do danej klasy:


- M_1 – model szacujący przynależność do klasy wyższej niż 1,
- M_2 – model szacujący przynależność do klasy wyższej niż 2,
- M_3 – model szacujący przynależność do klasy wyższej niż 3,
- M_4 – model szacujący przynależność do klasy wyższej niż 4,
- M_5 – model szacujący przynależność do klasy 2 (vs klasa 1,3,4,5),
- M_6 – model szacujący przynależność do klasy 3 (vs klasa 1,2,4,5),
- M_7 – model szacujący przynależność do klasy 4 (vs klasa 1,2,3,5).

Do selekcji cech zastosowano sekwencyjną selekcję cech (ang. sequential feature selection), która wybiera podzbiór cech diagnostycznych, dla których występuje najmniejszy błąd klasyfikacji. Jako kryterium błędu klasyfikacji wykorzystano regresję logistyczną.

Ze względu na gradacyjny charakter zmiennych, np. cechy pochodzące z analiz danych finansowych przedsiębiorstw (bilans oraz rachunek zysków i strat) można było zastosować uciągloną postać cechy diagnostycznej za pomocą wagi dowodu WoE (ang. weight of evidence).

Janek br7

Poniższy rysunek przedstawia schemat działania budowy pojedynczego modelu.



Rysunek 2. Schemat budowy pojedynczego podmodelu

Drugi etap fuzji to integracja wyjść z poszczególnych modeli $M_1, \dots, M_7$ budowanych niezależnie. Do integracji pojedynczych modeli zastosowano sieć SVM. Wyniki zostały zaprezentowane w tabeli 9 oraz na rysunku 3.

Na podstawie wyników można zauważyć większą przewagę fuzji integratorów pracujących w zespole, w porównaniu do pojedynczych klasyfikatorów.

Tabela 9. Porównanie dokładności klasyfikacji danych fuzji klasyfikatorów oraz pojedynczych klasyfikatorów

	Logistic regression + SVM	SVM	Decision tree	Ordinal regression	Fuzzy KNN
Mean	82.03%	78.35%	79.07%	69.06%	78.37%
Median	82.40%	78.44%	79.67%	69.12%	78.45%
Std	2.78%	2.70%	2.81%	2.82%	2.95%

Confusion Matrix

	1	2	3	4	5	
1	18.30 8.27%	2.40 1.10%	0.16 0.08%	0.00 0.00%	0.00 0.00%	87.73% 12.27%
2	2.94 1.35%	66.00 29.86%	6.36 2.89%	0.00 0.00%	0.00 0.00%	87.61% 12.39%
3	0.00 0.00%	10.08 4.56%	66.28 29.99%	8.04 3.65%	0.00 0.00%	78.48% 21.52%
4	0.00 0.00%	0.12 0.06%	5.08 2.31%	23.26 10.53%	2.44 1.12%	75.09% 24.91%
5	0.00 0.00%	0.00 0.00%	0.00 0.00%	2.10 0.97%	7.44 3.37%	78.32% 21.68%
	1	2	3	4	5	
	86.12% 13.88%	83.94% 16.06%	85.02% 14.98%	69.54% 30.46%	75.38% 24.62%	82.03% 17.97%

Rysunek 3. Macierz pomyłek otrzymana po 50-krotnej walidacji krzyżowej


Osiągnięciem naukowym przedstawionym w tej publikacji było opracowanie skutecznej metodyki rozwiązania problemu diagnostycznego w postaci oszacowania kondycji finansowej przedsiębiorstw za pomocą specjalistycznej dwuetapowej fuzji metod sztucznej

inteligencji. Dodatkowo zaproponowano nowatorskie kodowanie zmiennych dla cech mających charakter gradacyjny (dane finansowe), w formie ucięglonej postaci cechy diagnostycznej za pomocą wagi dowodu WoE (ang. weight of evidence). Główną różnicą między pracami [3] i [4] był zbiór danych, który został znacznie poszerzony w pracy [4].

5. Klasyfikacja stanu wiertła podczas wiercenia w płycie laminowanej na podstawie zarejestrowanych sygnałów z sensorów pomiarowych

5.1 Zastosowanie uczenia maszynowego w zagadnieniu klasyfikacji stanu wiertła podczas wiercenia w płycie laminowanej

W pracy [5] podjęto próbę budowy automatycznego systemu diagnostycznego klasyfikującego stan wiertła do jednej z dwóch klas: wiertło wystarczające ostre, aby dalej wykonywać operację wiercenia (klasa „useful”) oraz wiertło na tyle stępione, że powinno się wymienić je na nowe (klasa „useless”), a tym samym uniknąć szkód wyrządzonych w procesie wiercenia na linii produkcyjnej. Stan „useful” oznacza, że narzędzie jest bezwarunkowo zdolne do dalszej pracy. Natomiast nawet jednorazowa sygnalizacja stanu „useless” przez system diagnostyczny oznacza, że narzędzie nie nadaje się do dalszej pracy i musi być wymienione na nowe. Zarejestrowano 5 różnych sygnałów pomiarowych z 4 czujników pomiarowych, takich jak czujnik kontaktowy emisji akustycznej, akcelerometr, siłomierz, mikrofon Bruel & Kjaer. Tor pomiarowy został zaprezentowany na rysunku 4.



Rysunek 4. Schemat toru pomiarowego

Do generacji bazy danych użyto 6 różnych wiertel, z czego jedno wiertło było referencyjne (niestępiane), natomiast pozostałe były stopniowo tępiące pod mikroskopem. Zarejestrowano w sumie 247 różnych przypadków stanu wiertła – 102 przypadki stanu jeszcze ostrego wiertła (klasa „useful”) oraz 145 przypadki stępionego, które powinno się wymienić na nowe (klasa „useless”).

Używając wyżej wymienionych 4 sensorów, na podstawie 5 zarejestrowanych sygnałów, takich jak siła posuwu (F), moment tnący (M), hałas (C), wibracje (V), emisja akustyczna (AE), wygenerowano następujące potencjalne cechy diagnostyczne (155 potencjalnych cech):

1. W dziedzinie czasu (85 cech):
 - a. arithmetic mean of signals (5 cech),
 - b. standard deviation of signals (5 cech),
 - c. variance of signals (5 cech),
 - d. histogram (50 cech),
 - e. skewness of signals (5 cech),
 - f. kurtosis of signals (5 cech),
 - g. RMS of signals (5 cech),
 - h. ratio of peak magnitude to RMS of signals (5 cech).
2. W dziedzinie częstotliwości (50 cech):
 - a. 10 cech ze spektrum FFT, dla każdego z pięciu zarejestrowanych sygnałów zgodnie z poniższym wzorem:

$$FFT_n = count(f > mean(abs(FFT)) + (n + 2) std(abs(FFT)))$$
 gdzie $n=1,2,...,10$
3. W dziedzinie czasowo-częstotliwościowej (20 cech):
 - a. cztery poziomy energii dla drugiego poziomu dekompozycji falkowej, dla 5 sygnałów (20 cech).

Następnie dla 7 różnych rodziny falek zastosowano sekwencyjną selekcję cech (ang. sequential feature selection), dzięki której zawężono zbiór cech diagnostycznych. Cechy te zaprezentowano w tabeli 11.

Janek lub

Tabela 10. Wyniki selekcji cech diagnostycznych wygenerowanych w dziedzinie czasu, częstotliwości i czasowo-częstotliwościowej

No	Wavelet	Features
1	db1	FFT7_M FFT2_F FFT3_V FFT5_V FFT3_C FFT6_C Mean_F VarAE VarF HistAE3 HistAE7 HistAE10 HistM1 HistM6 HistF3 HistF7 HistF9 HistV7 KurtosisM RMS_AE EnergyAE1 EnergyV1
2	db5	FFT4_AE FFT7_M FFT2_F FFT3_F FFT4_F FFT5_F FFT3_VcFFT4_V FFT1_C FFT3_C FFT6_C FFT10_C Mean_F Mean_V VarAE VarF VarC HistAE4 HistAE7 HistAE10 HistF3 HistF7 HistF8 HistF9 HistV7 KurtosisM KurtosisC RMS_AE RMS_C EnergyAE1 EnergyV1 EnergyC4
3	db20	FFT4_AE FFT4_M FFT5_M FFT7_M FFT2_F FFT4_F FFT5_F FFT3_V FFT4_V FFT1_C FFT3_C FFT6_C Mean_F VarAE VarF HistAE6 HistAE7 HistAE10 HistF3 HistF7 HistF8 HistF9 HistV7 HistV8 KurtosisM KurtosisC RMS_AE EnergyAE1 EnergyV1
4	coif4	FFT4_AE FFT7_M FFT2_F FFT3_V FFT4_V FFT10_C Mean_F VarF VarC HistAE7 HistF3 HistF7 HistF9 HistV7 KurtosisM RMS_AE RMS_C EnergyV1
5	sym2	FFT4_AE FFT7_M FFT2_F FFT3_V FFT4_V FFT10_C Mean_F VarF VarC HistAE7 HistF3 HistF7 HistF9 HistV7 KurtosisM RMS_AE RMS_C EnergyV1
6	discrete Meyer	FFT4_AE FFT7_M FFT2_F FFT3_V FFT5_V FFT10_C Mean_F VarF VarC HistAE7 HistF2 HistF3 HistF9 HistV7 KurtosisM RMS_AE RMS_C EnergyV1
7	rbio1.3	FFT2_F FFT3_V FFT5_V FFT3_C FFT6_C Mean_M Mean_F VarAE VarF HistAE6 HistAE10 HistM1 HistM10 HistF3 HistF7 HistF9 HistV7 RMS_AE peak2RMS_M EnergyAE1 EnergyV1

We właściwym procesie diagnostyki wybrano najlepsze znane wówczas klasyfikatory: SVM, procedury agregujące za pomocą drzew decyzyjnych (ang. ensemble of decision tree), lasy losowe (ang. random forest). Na podstawie wyselekcjonowanych cech dla 7 różnych rodzin falek przeprowadzono eksperymenty numeryczne klasyfikacji dwóch stanów wiertła („useful” i „useless”). Ze względu na małą liczbę danych (247) zastosowano walidację krzyżową metodą „leave-one-out,” w których dla wszystkich próbek danych tylko jedna próbka była testowana, natomiast pozostałe stanowiły zbiór uczący. Wyniki klasyfikacji przedstawione zostały w tabeli 11.

Janek Kutek

Tabela 11. Wyniki klasyfikacji stanu wiertła dla 3 różnych metod klasyfikacji na podstawie wyselekcjonowanych cech diagnostycznych

No	Applied wavelet	Best level	Accuracy [%] DT/SVM/RF	Standard deviation [%] DT/SVM/RF
1	db1	2	91.10/93.91/95.14	4.16/3.24/1.10
2	db5	2	91.48/94.73/95.12	4.41/2.32/2.34
3	db20	2	89.50/95.13/95.13	7.75/4.46/3.08
4	coif4	2	91.10/93.55/95.15	4.85/3.53/1.78
5	sym2	2	91.10/94.34/95.13	4.59/3.83/3.05
6	Meyer	2	91.93/94.31/94.33	6.63/6.01/4.61
7	rbio1.3	2	91.90/93.12/95.96	2.50/2.26/1.39

Najlepszy wynik dokładności klasyfikacji otrzymano dla lasów losowych (95,96%) po zastosowaniu zbioru cech diagnostycznych dla rodziny falek biortogonalnych (biorthogonal wavelet rbio1.3). Cechy diagnostyczne zastosowane dla najlepszego wyniku klasyfikacji zaprezentowano w tabeli 12.

Tabela 12. Cechy diagnostyczne zastosowane dla najlepszego wyniku klasyfikacji

Selected features
FFT5_AE, FFT5_M, FFT7_M, FFT2_F, FFT10_C, Mean_F, StdF, VarAE, VarF, HistAE5, HistAE6, HistAE10, HistM1, HistF, HistF7, HistF9, HistV5, SkewnessC, KurtosisM, RMS_AE, EnergyM2, EnergyF, EnergyM2, EnergyC2, EnergyC2, EnergyC3, EnergyC3, EnergyM1

Osiągnięciem naukowym przedstawionym w tej publikacji było opracowanie skutecznej metodyki rozwiązania problemu diagnostycznego w postaci klasyfikacji dwóch stanów wiertła podczas wiercenia w płycie laminowanej za pomocą metod sztucznej inteligencji. Na uwagę zasługuje duży zbiór potencjalnych cech diagnostycznych, które pozyskano w dziedzinie czasu, częstotliwości i czasowo-częstotliwościowej. Wykorzystano sekwencyjną selekcję cech z modyfikacją pozwalającą na zastosowanie dowolnego klasyfikatora jako kryterium wejścia danej cechy do finałowego zbioru deskryptorów. Następnie zaimplementowano 3 klasyfikatory, które pozwoliły na skuteczne rozwiązanie podejmowanego problemu.

5.2. Zastosowanie uczenia głębokiego (ang. deep learning) w zagadnieniu klasyfikacji stanu wiertła podczas wiercenia w płycie laminowanej za pomocą algorytmu LSTM

W pracy [13] przedstawiono podejście klasyfikacji w oparciu o algorytm uczenia głębokiego LSTM (ang. long-short time memory). W porównaniu do pracy [5] (klasyfikowano stan wiertła tylko do dwóch klas) rozszerzono klasyfikację o dodatkową klasę pośrednią, co oznacza, że w pracy [13] system diagnostyczny rozpoznawał trzy klasy stanu wiertła (zieloną,

żółtą i czerwoną). Stan „zielony” oznacza, że narzędzie jest bezwarunkowo zdolne do dalszej pracy. Natomiast nawet jednorazowa sygnalizacja stanu „czerwonego” przez system diagnostyczny oznacza, że wiertło nie nadaje się do dalszej pracy i musi być wymienione na nowe. Stan „żółty” oznacza sytuację niejednoznaczną, która wymaga manualnej kontroli.

W pracy [13] wykorzystano algorytm sieci rekurencyjnych (ang. recurrent neural network – RNN) w modelowaniu sekwencji w uczeniu głębokim. Dane sekwencyjne to dane, które zależą od czasu, np. klasyfikacja sygnałów czasowych, wykrywanie wzorców w sekwencjach, sygnały audio etc. Takimi danymi sekwencyjnymi mogą być sygnały czasowe zarejestrowane z 4 sensorów umieszczonych na stanowisku pomiarowym do rozpoznawania stanu wiertła.

Głównymi problemami, które możemy napotkać w sieciach rekurencyjnych są problem znikającego gradientu dla odległych w czasie relacji (zanika wykładniczo z czasem) oraz niestabilność uczenia związana z tzw. gradientem eksplodującym. Oba te problemy rozwiązuje algorytm LSTM (ang. long short-term memory) przez zastosowanie bramek wejściowych, wyjściowych oraz bram zapominania, które sterują zapamiętywanymi informacjami.

Baza danych składała się z 242 próbek, dla których dokonano akwizycji 5 zmierzonych sygnałów, takich jak siła posuwna (ang. feed force – F), moment tnący (ang. cutting torque – M), hałas (ang. noise – C), vibracje (ang. vibration – V) oraz emisja akustyczna (ang. acoustic emission – AE). Dla każdego zarejestrowanego sygnału 254 próbek przeprowadzono podział na 58 okien o długości 1024 próbek. Następnie dla każdego okna obliczono 32-punktową dyskretną transformatę Fouriera – DFT, tworząc w ten sposób sekwencje danych, które mogą być użyte do klasyfikacji za pomocą algorytmu LSTM uczenia głębokiego. Zatem dla każdego z pięciu sygnałów uzyskano 32 cechy diagnostyczne, czyli w sumie 160, oraz 20 cech uzyskanych z korelacji Spearmana i Pearsona, dając w sumie 180 cech diagnostycznych 58 sekwencji danych.

Wyniki eksperymentów numerycznych przedstawiono w tabeli 13. Średnia dokładność klasyfikacji rozpoznania stanu wiertła dla 3 klas wynosi 81.32%.

Tabela 13. Wyniki klasyfikacji stanu wiertła dla 3 klas (zielona, żółta, czerwona) za pomocą algorytmu LSTM uczenia głębokiego


Number of drill tested	Training accuracy	Testing accuracy
Drill 1	100%	100%
Drill 2	100%	88.89%
Drill 3	100%	77.78%
Drill 4	100%	65.71%
Drill 5	100%	88.89%
Drill 6	100%	66.67%
Average	100%	81.32%

Osiągnięciem naukowym przedstawionym w tej publikacji było opracowanie skutecznej metodyki rozwiązania problemu diagnostycznego w postaci klasyfikacji trzech stanów wiertła podczas wiercenia w płycie laminowanej za pomocą metod sztucznej inteligencji. Na uwagę zasługuje fakt, iż zastosowano nowatorski algorytm uczenia głębokiego LSTM, który pozwolił na uzyskanie satysfakcjonującego wyniku dla analizowanych 3 stanów wiertła w procesie wiercenia. Za osiągnięcie należy uznać też przekształcenie tradycyjnego szeregu czasowego sygnału, na serie sekwencji, gdyż tylko w takim kodowaniu algorytm uczenia głębokiego LSTM ma szansę poprawnie działać.

6. Klasyfikacja stanu wiertła podczas wiercenia w płycie laminowanej na podstawie danych obrazowych

6.1 Uczenie maszynowe w zagadnieniu klasyfikacji stanu wiertła podczas wiercenia w płycie laminowanej na podstawie danych obrazowych

W pracy [6] zastosowano inną metodę budowy automatycznego systemu diagnostycznego wiertła w trybie online (bez wyłączania urządzenia) w porównaniu do pracy [5], a mianowicie skupiono się na obrazach otworów tuż po procesie wiercenia. Za pomocą przymocowanego aparatu wykonano 900 zdjęć (450 zdjęć otworu z frontu i 450 zdjęć otworu z tyłu płyty laminowanej). Przykłady tych zdjęć dla dwóch różnych klas przedstawiono na rysunku 5.




Rysunek 5. a) wygląd otworu z frontu płyty dla nowego wiertła b) wygląd otworu z frontu płyty dla stępionego wiertła, c) wygląd otworu z tyłu płyty dla nowego wiertła d) wygląd otworu z tyłu płyty dla stępionego wiertła

Na podstawie bazy danych dokonano ekstrakcji potencjalnych cech diagnostycznych, które separowały dwie analizowane klasy wiertel – ostre („useful”) i stępione („useless”). Na podstawie wielu analiz bazy danych stwierdzono, że bardzo istotnym czynnikiem wpływającym na manualną diagnozę przez eksperta jest różnica maksymalnej średnicy otworu i średnica wiertła. Może to zostać opisane następująco:

$$A = \frac{D_{MAX} - D}{2}$$

gdzie D_{MAX} jest maksymalną średnicą otworu, a D jest średnicą wiertła. Rysunek 6 przedstawia powyższe zależności.

Jan Kubiś



Rysunek 6. Interpretacja średnic używanych w generacji cech numerycznych

Jako rezultat analiz i badań wygenerowano 8 cech diagnostycznych, które posłużą w procesie klasyfikacji stanu wiertła na podstawie zdjęć otworów. Są to następujące deskrytory numeryczne:

1. promień okręgu wpisanego w otwór,
2. promień okręgu opisanego w otwór,
3. powierzchnia otworu,
4. wypukłość powierzchni,
5. obwód otworu,
6. długość osi większej,
7. długość osi mniejszej,
8. współczynnik solidności.

Pomimo, że wygenerowano tylko 8 cech diagnostycznych, podjęto próbę selekcji cech najlepiej dyskryminujących dwie klasy stanu wiertła. Do tego celu zaimplementowano korelacyjne metody selekcji, takie jak miara Fishera, FCBF (ang. fast correlation based feature selection) i CFS (ang. correlation-based feature selection). Wyniki zaprezentowano w tabeli 14 i 15. Jako klasyfikatory wykorzystano klasyfikator k-NN i sieć SVM.

Tabela 14. Dokładność klasyfikacji w rozpoznawaniu stanu wiertła na podstawie obrazu frontu otworu

Classifier	Features Selection Method			
	<i>All</i>	<i>Fisher</i>	<i>FCBF</i>	<i>CFS</i>
kNN	88.38%	90.01%	90.17%	91.06%
SVM	93.78%	91.07%	91.07%	91.07%

Tabela 15. Dokładność klasyfikacji w rozpoznawaniu stanu wiertła na podstawie obrazu z tyłu otworu

Classifier	Features Selection Method			
	<i>All</i>	<i>Fisher</i>	<i>FCBF</i>	<i>CFS</i>
kNN	92.85%	92.85%	92.85%	92.85%
SVM	94.66%	91.96%	89.28%	88.39%

W obu przypadkach eksperymentów numerycznych klasyfikacji stanu wiertła na podstawie otworu po procesie wiercenia (z frontu i z tyłu płyty) największą dokładność


uzyskano dla sieci SVM i po zastosowaniu wszystkich cech diagnostycznych (bez użycia selekcji) – 94,66%.

Osiągnięciem naukowym przedstawionym w tej publikacji było opracowanie skutecznej metodyki rozwiązania problemu diagnostycznego w postaci klasyfikacji dwóch stanów wiertła podczas wiercenia w płycie laminowanej na podstawie danych obrazowych za pomocą metod uczenia maszynowego. Okazuje się, że bazując tylko na danych obrazowych otworów po procesie wiercenia można z dużo większą dokładnością oszacować stan wiertła. Wygenerowano cechy diagnostyczne, które razem z zastosowanymi algorytmami selekcji cech oraz tradycyjnymi klasyfikatorami uczenia maszynowego pozwoliły uzyskać dokładność klasyfikacji na poziomie około 94%.

6.2 Uczenie głębokie w zagadnieniu klasyfikacji stanu wiertła podczas wiercenia w płycie laminowanej na podstawie danych obrazowych

W pracy [9] zastosowano zupełnie odrębne podejście niż w pracy [6]. Zamiast używać uczenia maszynowego i ręcznie generować cechy diagnostyczne [6], zastosowano sieć CNN uczenia głębokiego (ang. deep learning). W sieci CNN cechy diagnostyczne są automatycznie wyznaczane przez skomplikowaną architekturę uczenia głębokiego (m.in. przez filtry). Rysunek 7 przedstawia porównanie tradycyjnego podejścia za pomocą uczenia maszynowego z podejściem za pomocą uczenia głębokiego.

Baza danych składała się tylko z 900 zdjęć otworów po procesie wiercenia. Warunkiem koniecznym skutecznego zastosowania uczenia głębokiego w roli klasyfikatora jest posiadanie bardzo dużej liczby danych uczących (w tym przypadku zdjęć otworów). 900 zdjęć to stanowczo za mało, aby uzyskać dokładność klasyfikacji na poziomie zadawalającym. Aby zwiększyć liczbę próbek danych uczących, wygenerowano sztucznie odpowiednio 11700 i 33300 zdjęć otworów na podstawie bazowych 900 sztuk. Do generacji zastosowano rotację i skalowanie zdjęć oryginalnych. Wyniki klasyfikacji są zaprezentowane w tabeli 17. Najlepszy wynik klasyfikacji to 95,5%, który jest wyższy od dokładności klasyfikacji opisanej w pracy [6].



Rysunek 7. Porównanie tradycyjnego podejścia do klasyfikacji – uczenie maszynowe (ang. machine learning) vs podejście za pomocą uczenia głębokiego (ang. deep learning)

Janek Lech


Tabela 16. Wyniki eksperymentu numerycznego przy rozpoznawaniu stanu wiertła na podstawie zdjęć otworów za pomocą sieci CNN uczenia głębokiego (ang. deep learning)

No of images	Accuracy [%]
900	66.6%
11700	89%
33300	95.5%

Osiągnięciem naukowym przedstawionym w tej publikacji było opracowanie skutecznej metodyki rozwiązania problemu diagnostycznego w postaci klasyfikacji dwóch stanów wiertła podczas wiercenia w płycie laminowanej na podstawie danych obrazowych za pomocą metod uczenia głębokiego algorytmu CNN. Na uwagę zasługuje fakt, że za pomocą algorytmu CNN uczenia głębokiego cechy diagnostyczne są generowane automatycznie, bez nadzoru przez wyżej wspomniany algorytm. W porównaniu do uczenia maszynowego podejście za pomocą uczenia głębokiego, zaprezentowane w pracy [9], wydaje się być rzetelniejsze i daje lepszą dokładność niż uczenie maszynowe przedstawione w pracy [6]. Dość istotnym osiągnięciem w uczeniu głębokim jest nie tylko jego implementacja, ale także odpowiedni dobór architektury sieci CNN.

6.3 Uczenie transferowe (ang. transfer learning) w uczeniu głębokim w zagadnieniu klasyfikacji stanu wiertła podczas wiercenia w płycie laminowanej na podstawie danych obrazowych

W pracy [10] w porównaniu do pracy [9] skomplikowano zadanie i wyodrębiono trzecią klasę wiertła, tzw. klasę pośrednią. Baza danych została więc podzielona na trzy klasy: klasę „czerwoną”, „żółtą”, „zieloną”. Stan „zielony” oznacza, że narzędzie jest bezwarunkowo zdolne do dalszej pracy. Natomiast nawet jednorazowa sygnalizacja stanu „czerwonego” przez system diagnostyczny oznacza, że narzędzie nie nadaje się do dalszej pracy i musi być wymienione na nowe. Stan „żółty” oznacza sytuację niejednoznaczną, która wymaga dodatkowej interpretacji. Przykłady zdjęć otworów po procesie wiercenia, reprezentujących trzy wyżej wymienione klasy zaprezentowano na rysunku 8.



Rysunek 8. Przykłady zdjęć otworów reprezentujących 3 klasy stanu wiertła: a) klasa zielona, b) klasa żółta, c) klasa czerwona

Ze względu na zbyt małą liczbę danych uczących dla sieci CNN uczenia głębokiego, zamiast sztucznie rozszerzać bazę danych za pomocą generacji pochodnych obrazów otworów

za pomocą skalowania i rotacji zastosowano nowatorskie podejście uczenia transferowego w uczeniu głębokim (ang. transfer learning).

W pracy [10] do zagadnienia uczenia transferowego zastosowano nauczoną już sieć AlexNet. Model tej sieci został nauczony z użyciem bazy danych składającej się z ponad miliona próbek pochodzących z różnych 1000 klas. Sieć AlexNet składała się ze struktury 9 warstw i 25 podwarstw.

Ideą uczenia transferowego jest zastosowanie już istniejącej nauczonej sieci na dużej liczbie próbek uczących, a następnie przetransferowanie jej zdolności generalizujących do innego zagadnienia oraz douczenie sieci korzystając z bazy danych faktycznego zagadnienia, które chcemy rozwiązać. W tym celu pozostawiono 6 pierwszych warstw sieci AlexNet, a następnie dołączono warstwy sieci dostosowane do zagadnienia oceny stanu wiertła (problem 3-klasowy zamiast 1000-klasowy).

Nowością w pracy [10] jest także transfer wygenerowanych i wyselekcjonowanych cech diagnostycznych z dostosowanej sieci AlexNet do innego klasyfikatora niż tego użytego w sieci CNN uczenia głębokiego, a mianowicie sieci SVM. Okazuje się, że połączenie metod ekstrakcji cech z sieci CNN uczenia głębokiego i użycie klasyfikatora uczenia maszynowego dało najlepsze rezultaty. Wyniki są przedstawione w tabeli 17.

Tabela 17. Wyniki klasyfikacji stanu wiertła dla 3 różnych klas („zielona,” „żółta,” „czerwona”) po zastosowaniu uczenia głębokiego (ang. deep learning)

Deep learning algorithm	Accuracy[%]
Standard CNN	35%
Pretrained CNN	85%
Pretrained CNN+SVM (C=1000, gamma=0.01)	93.4%

Osiągnięciem naukowym przedstawionym w tej publikacji było opracowanie skutecznej metodyki rozwiązania problemu diagnostycznego w postaci klasyfikacji trzech stanów wiertła podczas wiercenia w płycie laminowanej na podstawie danych obrazowych, za pomocą metod uczenia głębokiego algorytmu CNN wykorzystującego uczenie transferowe. Osiągnięciem naukowym jest modyfikacja i implementacja algorytmu CNN w postaci zastosowania już wytrenowanej sieci AlexNet na podstawie 1,2 miliona zdjęć i 1000 analizowanych klas. Pozwoliło to na rozszerzenie liczby klas z dwóch do trzech, nie tracąc przy tym satysfakcjonującej wartości dokładności klasyfikacji.

6.4 Uczenie hybrydowe (uczenie maszynowe + uczenie głębokie) w zagadnieniu klasyfikacji stanu wiertła podczas wiercenia w płycie laminowanej

W pracy [14] połączono metody sztucznej inteligencji zaprezentowane w pracy [6,9,10]. Idea polegała na połączeniu cech diagnostycznych wygenerowanych ręcznie (praca [6]), jak i pozyskanych automatycznie z ostatnich warstw uczenia głębokiego (praca [9, 10]). Wszystkie te cechy jednocześnie brały udział w rozpoznaniu 3 stanów wiertła („zielony”, „żółty”, „czerwony”) za pomocą wieloklasowego klasyfikatora SVM. Natomiast do automatycznego wygenerowania cech diagnostycznych wykorzystano już wytrenowaną i dostosowaną do obecnego problemu sieć AlexNet. Wyniki zostały zaprezentowane w tabeli 18. Jak widać,

standardowa sieć CNN uczenia głębokiego nie może zostać wykorzystana dla 242 próbek, gdyż wymaga zbioru uczącego tysięcy próbek uczących. Dlatego też wykorzystano już wytrenowaną sieć AlexNet, którą następnie zaadaptowano do bieżącego problemu – osiągnięto dokładność klasyfikacji na poziomie 85%. Trzecim podejściem była ekstrakcja cech diagnostycznych z podejścia drugiego i zastosowanie klasyfikatora SVM, który dał lepszy rezultat – na poziomie 93,4%. Natomiast połączenie cech diagnostycznych wyznaczonych manualnie oraz cech z podejścia trzeciego pozwoliło na dodatkowe zwiększenie dokładności do poziomu 95,9%.

Tabela 18. Porównanie wyników klasyfikacji stanu wiertła dla 3 różnych klas („zielona,” „żółta,” „czerwona”) dla 4 różnych podejść uczenia głębokiego

Deep learning algorithm	Feature selection	Accuracy [%]
Standard CNN	Automatically extracted one based on deep learning	35%
Pretrained CNN	Automatically extracted one based on deep learning	85%
Pretrained CNN+SVM (C=1000, gamma=0.01)	Automatically extracted one based on deep learning	93.4%
Hybrid approach: Pretrained CNN+SVM (C=1000, gamma=0.01)	Fusion of automatically extracted one based on deep learning and hand crafted one	95.9%


Osiągnięciem naukowym przedstawionym w tej publikacji było opracowanie skutecznej metodyki rozwiązania problemu diagnostycznego w postaci klasyfikacji trzech stanów wiertła podczas wiercenia w płycie laminowanej na podstawie danych obrazowych za pomocą podejścia hybrydowego. Osiągnięciem naukowym jest połączenie cech uzyskanych manualnie oraz automatycznie bez nadzoru (uczenie głębokie), które razem stanowiły wejście na wieloklasową sieć SVM, gdyż jako klasyfikator dawał lepsze rezultaty niż ostatnia warstwa klasyfikacyjna sieci CNN. Dodatkowym osiągnięciem naukowym była taka modyfikacja architektury już wytrenowanej sieci AlexNet, aby można było nauczyć ją do podejmowanego w pracy problemu.

7. Generacja, selekcja cech diagnostycznych oraz fuzje klasyfikatorów w zagadnieniu diagnostyki raka jasnokomórkowego nerki pod kątem identyfikacji stadium zaawansowania w skali Fuhrmana

W pracy [7] podjęto próbę diagnostyki raka jasnokomórkowego nerki z uwzględnieniem tzw. skali Fuhrmana. Skala ta ma 4 stopnie, gdzie stopień pierwszy odpowiada najniższemu stopniowi zaawansowania raka nerki, natomiast czwarty odpowiada najwyższemu stopniowi zaawansowania raka.

Baza danych została zbudowana od podstaw przez fotografowanie pod mikroskopem wycinków biopsji pacjentów. Kolejnym etapem było wyodrębnienie pojedynczych komórek nerki i potraktowanie ich jako region zainteresowania (ang. region of interest – ROI). Finalnie baza danych składała się z 3446 obrazów komórek nerki.

Zauważono, że ogromną rolę w klasyfikacji 4 stanów zaawansowania jasnokomórkowego raka nerki mają rozmiary jąder w jądrach komórek nowotworowych i na tym fakcie skupiono uwagę podczas generacji cech diagnostycznych. Rysunek 9 przedstawia ilustrację tego problemu diagnostycznego.



Rysunek 9. Graficzna ilustracja problemu diagnostycznego. Kolumna 1 – obraz oryginalny, kolumna 2 – obraz po segmentacji. Wiersz 1 – drugi stopień zaawansowania raka nerki, wiersz 2 – trzeci stopień zaawansowania raka nerki, wiersz 3 – czwarty stopień zaawansowania raka nerki

Wygenerowano 31 cech diagnostycznych na podstawie wysegmentowanych obrazów ROI. Cechy te to: 5 cech Haralicka, 13 cech statystycznych, 4 cechy teksturowe, 6 cech morfometrycznych oraz 3 cechy oparte na kolorze. Wszystkie cechy zostały dalej poddane selekcji cech, aby wybrać finalny zbiór deskryptorów numerycznych, najlepiej dyskryminujących wszystkie 4 klasy podejmowane w pracy. Jako metody selekcji cech zastosowano miarę Fishera - FM (ang. fisher measure), algorytmy genetyczne – GA (ang. genetic algorithms), lasy losowe (ang. random forests), miarę korelacyjną CFS (ang. correlation feature selection), miarę korelacyjną FCBF (ang. fast correlation based filter). Natomiast jako klasyfikatory

w trybie indywidualnym zostały użyte najnowsze metody na czas publikacji artykułu: sieć SVM (ang. support vector machine) i lasy losowe (ang. random forests). Dodatkowo stworzono dwie fuzje klasyfikatorów. Pierwsza fuzja klasyfikatorów składa się ze wszystkich kombinacji metod selekcji cech i klasyfikatora indywidualnego (SVM i następnie RF), natomiast druga fuzja klasyfikatorów (ang. limited ensemble) tylko z wybranych, które dają najlepszą dokładność klasyfikacji (SVM + FM, SVM + RF, RF + RF, RF + FCBF). Wyniki klasyfikacji zostały przedstawione w tabeli 19 i 20.

Tabela 19. Dokładność rozpoznawania skali Fuhrmana wszystkich rodzajów klasyfikatorów

Classifier	SVM + FM	SVM + GA	SVM + RF	SVM + CFS	SVM + FCBF	RF + FM	RF + GA	RF + RF	RF + CFS	RF + FCBF	FE	LE
Grade 1	0.978	0.967	0.981	0.952	0.971	0.975	0.965	0.975	0.947	0.972	0.974	0.981
Grade 2	0.951	0.947	0.962	0.925	0.948	0.950	0.943	0.973	0.932	0.941	0.943	0.976
Grade 3	0.922	0.898	0.931	0.911	0.918	0.919	0.898	0.943	0.926	0.914	0.917	0.943
Grade 4	0.861	0.859	0.867	0.843	0.860	0.860	0.857	0.858	0.847	0.860	0.854	0.874

Tabela 20. Macierz pomyłek dotycząca klasyfikacji za pomocą ograniczonej fuzji klasyfikatorów (ang. limited ensemble)

	Grade 1	Grade 2	Grade 3	Grade 4	Sensitivity	Specificity
Grade 1	1142	16	6	0	98.1%	98.9%
Grade 2	12	1106	14	1	97.6%	98.1%
Grade 3	8	17	740	21	94.1%	98.0%
Grade 4	3	11	32	317	87.3%	99.3%

Osiągnięciem naukowym przedstawionym w tej publikacji było opracowanie skutecznej metodyki rozwiązania problemu diagnostycznego w postaci diagnostyki raka jasnomórkowego nerki pod kątem identyfikacji stadium zaawansowania w skali Fuhrmana. Ze względu na złożoność problemu diagnostycznego wygenerowano wiele potencjalnych cech diagnostycznych, a następnie zaimplementowano wiele metod selekcji cech. Dodatkowo osiągnięciem naukowym jest zaimplementowanie skutecznej fuzji klasyfikatorów, które w tym podejmowanym problemie dały najlepszy wynik dokładności rozpoznania.

8. Diagnostyka raka piersi na podstawie publicznie dostępnej bazy “Digital Database for Screening Mammography” (DDSM)

8.1 Uczenie maszynowe w diagnostyce raka piersi

W pracy [11] wykorzystano publiczną bazę danych DDSM, która zawierała 10000 regionów zainteresowania (ROI) do diagnostyki raka piersi za pomocą uczenia maszynowego. Głównym istotnym elementem diagnostyki jest konwersja obrazu do postaci jednowymiarowego wektora za pomocą przekształcenia krzywymi Hillberta. Umożliwia to zastosowanie wielu miar dotyczących szeregów czasowych, takich jak chociażby miary statystyczne.

W rezultacie zaprezentowano 122 potencjalne cechy diagnostyczne, które są następujące:

- 35 cech wyznaczonych na podstawie reprezentacji obrazu w postaci krzywych Hillberta,
- 14 cech wyznaczonych na podstawie reprezentacji obrazu w postaci koncentrycznych pierścieni,
- 5 cech wyznaczonych na podstawie maksymalnych deskryptorów regionów,
- 2 cechy wyznaczone na podstawie algorytmu wypalania lasów,
- 4 cechy wyznaczone na podstawie macierzy współwystępowania na poziomie szarości (gray-level co-occurrence matrix – GLCM),
- 9 cech wyznaczonych na podstawie wymiaru fraktalnego,
- 36 cech wyznaczonych na podstawie fraktalnej analizy tekstury,
- 16 cech wyznaczonych na podstawie 4-stopniowej dekompozycji falkowej.

W eksperymencie numerycznym zastosowano trzy typy klasyfikatorów: sieć SVM, drzewa decyzyjne, lasy losowe. Problem diagnostyczny dotyczył dwuklasowego zagadnienia. Pierwsza klasa reprezentowała tkanki zdrowe (normal), natomiast klasa druga tkanki z nowotworem łagodnym i złośliwym łącznie (benign + malignant). Wyniki klasyfikacji zostały zaprezentowane w tabeli 21.

Jarek Kubiś

Tabela 21. Wynik klasyfikacji (średnia $\pm$ odchylenie standardowe) binarnej klasyfikacji tkanki zdrowej vs tkanki z nowotworem łagodnym i złośliwym (normal vs abnormal)

Feature set	SVM	Decision tree	Random forest
GLCM	63.32% ($\pm$ 2.43)	63.19% ($\pm$ 2.13)	64.66% ($\pm$ 3.40)
Fractal analysis	66.61% ($\pm$ 2.79)	64.55% ($\pm$ 2.23)	67.36% ($\pm$ 2.17)
Hilbert's image representation	57.18% ($\pm$ 2.15)	58.18% ($\pm$ 2.71)	61.88% ($\pm$ 3.23)
Kolmogorov-Smirnov	55.87% ($\pm$ 2.31)	55.66% ($\pm$ 1.90)	58.22% ($\pm$ 2.39)
Maximum sub-regions	60.26% ($\pm$ 2.13)	62.92% ($\pm$ 2.71)	61.52% ($\pm$ 2.63)
All descriptors (without FS ^a)	71.63% ($\pm$ 0.96)	70.11% ($\pm$ 2.53)	71.42% ($\pm$ 3.14)
All descriptors (with FS ^a)	80.01% ($\pm$ 5.05)	79.12% ($\pm$ 5.51)	81.09% ($\pm$ 4.51)

Osiągnięciem naukowym przedstawionym w tej publikacji było opracowanie skutecznej metodyki rozwiązania problemu diagnostycznego w postaci diagnostyki raka piersi na podstawie publicznie dostępnej bazy "Digital Database for Screening Mammography" (DDSM) za pomocą uczenia maszynowego. Ze względu na złożoność problemu diagnostycznego wygenerowano bardzo wiele złożonych cech diagnostycznych. Przykładem może tu być nowatorska konwersja obrazu do wektora jednowymiarowego za pomocą przekształcenia krzywymi Hilberta. Dodatkowo zastosowanie wartości dystansu z testu Kolmogorov-Smirnova do generacji cech obrazowych oraz wiele pozostałych nowych cech diagnostycznych.

8.2 Uczenie głębokie (ang. deep learning) w diagnostyce raka piersi

Praca [8] dotyczyła zastosowania głębokich sieci neuronowych typu konwolucyjnego (CNN) w diagnostyce nowotworu piersi. Baza danych zawierała 10000 regionów zainteresowania (ROI) w postaci zdjęć mammograficznych w odcieniach szarości. Idea zaimplementowana w pracy polegała na dodaniu dwóch „sztucznych” dodatkowych kanałów do jednokanałowej reprezentacji obrazów (obrazy w odcieniach szarości), dzięki czemu algorytmy uczenia głębokiego miały dodatkowe informacje podczas diagnostyki nowotworu piersi.

Pierwszą dodatkową składową jest informacja pozyskana z tzw. nieujemnej dekompozycji macierzy (ang. non-negative matrix factorization – NMF). Jednak wcześniej zastosowano konwersję obrazu do wektora za pomocą przekształcenia Hilberta. Dekompozycja macierzy za pomocą NMF pozwala na uzyskanie informacji, jak wyglądałby analizowany obraz, gdyby reprezentował przypadek zdrowy.

Dekompozycja NMF może być zapisana jako:


$$P=WH$$

gdzie: P – zadana macierz, W – jest macierzą bazową zawierającą w kolumnach poszczególne wektory bazowe, H – jest macierzą kodów zawierającą w poszczególnych kolumnach towarzyszące im odpowiednie współczynniki kodowe. Posiadając macierz W jesteśmy w stanie zrekonstruować dowolny obraz, wyznaczając liniową, nieujemną kombinację bazowych „zdrowych” komponentów (np. poprzez wykorzystanie macierzy pseudoodwrotnej Moore-Penrosa). Wynikiem tej dekompozycji jest znalezienie dla każdego

obrazu (nie tylko zdrowej tkanki) jego reprezentacji obliczonej z rekonstrukcji na podstawie komponentów pozyskanych z części obrazów zdrowych (ta próba nie brała udziału w uczeniu).


Drugą sztuczną składową stanowi rozkład nasycenia pikseli w całym jego obrazie z rozkładem w jego poszczególnych mniejszych fragmentach. W tym celu wykorzystano statystykę Kołmogorowa-Smirnowa.

Przykład tych przekształceń zaprezentowano na rysunku 10. W taki sposób powstał sztucznie wygenerowany obraz trzykanałowy, który może stanowić wejście sieci CNN (ang. Convolutional Neural Network) uczenia głębokiego.



Rysunek 10. Przykład reprezentacji obrazów mammograficznych w procesie ich rozpoznania.
W kolejnych wierszach: obraz oryginalny, rekonstrukcja NMF, samopodobieństwo w wyżej omówionym sensie

Cały realizowany proces generowania dwóch sztucznych kanałów do reprezentacji obrazu w skali RGB wygląda następująco:



Rysunek 11 Wizualizacja konwersji obrazu w odcieniach szarości do postaci RGB.

W roli klasyfikatora użyto sieć CNN uczenia głębokiego o architekturze przedstawionej w tabeli 22. Dodatkowo należy wspomnieć, że wszystkie obliczenia realizowano na kartach graficznych.

Tabela 22. Architektura sieci CNN uczenia głębokiego

no	Layer	Details
1	Image Input	128x128x3 images with zero-center normalization
2	First Convolution Layer	32 filters 5x5x3 convolutions with stride 1x1 and padding 2x2
3	Max Pooling	3x3 max pooling with stride 2x2 and padding 0x0
4	Activation	ReLU
5	Second Convolution Layer	32 filters 5x5 convolutions with stride 1x1 and padding 2x2
6	Activation	ReLU
7	Average Pooling	3x3 average pooling with stride 2x2 and padding 0x0
8	Third Convolution Layer	64 filters 5x5 convolutions with stride 1x1 and padding 2x2
9	Activation	ReLU
10	Average Pooling	3x3 average pooling with stride 2x2 and padding 0x0
11	First Fully Connected Layer	64 fully connected neurons
12	Activation	ReLU
13	Second Fully Connected Layer	2 fully connected neurons
14	Activation	Softmax
15	Classification Output cross-entropy	

Przeprowadzono dwa typy eksperymentów numerycznych, w których poddano klasyfikacji dane pochodzące z publicznie dostępnej bazy Digital Database for Screening Mammography (DDSM). Wszystkie eksperymenty numeryczne zostały przeprowadzone z użyciem 10-krotnej walidacji krzyżowej.

Pierwszy eksperyment polegał na rozpoznaniu 3 klas: tkanki zdrowej (ang. normal), tkanki z nowotworem łagodnym (ang. benign) oraz tkanki z nowotworem złośliwym (malignant). Drugi eksperyment dotyczył natomiast klasyfikacji dwuklasowej: tkanki zdrowej (normal) od reszty danych, czyli tkanki z nowotworem (benign + malignant). Wyniki klasyfikacji zaprezentowano w tabeli 23.

Tabela 23. Wyniki eksperymentów numerycznych w rozpoznawaniu raka piersi za pomocą sieci CNN uczenia głębokiego

	AUC	Sensitivity	Specificity	Accuracy
abnormal vs normal	0.919	82,28%	86,59%	85,82%
malignant vs non-malignant vs normal	0.909	73,36%	86,01%	84,75%


Osiągnięciem naukowym przedstawionym w tej publikacji było opracowanie skutecznej metodyki rozwiązania problemu diagnostycznego w postaci diagnostyki raka piersi na podstawie publicznie dostępnej bazy "Digital Database for Screening Mammography" (DDSM) za pomocą uczenia głębokiego. Na uwagę zasługuje nowatorskie podejście wygenerowania dwóch dodatkowych kanałów obrazu tworząc finalnie obraz trzykanałowy, jak w obrazie RGB. Osiągnięciem naukowym było zaproponowanie pierwszej dodatkowej składowej w postaci informacji pozyskanej z tzw. nieujemnej dekompozycji macierzy (ang. non-negative matrix factorization – NMF) oraz drugiej składowej na którą składa się

rozkład nasycenia pikseli w całym jego obrazie z rozkładem w jego poszczególnych mniejszych fragmentach. Zaproponowana architektura sieci uczenia głębokiego CNN pozwoliła na uzyskanie bardzo dobrej dokładności klasyfikacji.

8.3 Porównanie diagnostyki rozpoznawania raka piersi za pomocą uczenia maszynowego (ang. machine learning) oraz uczenia głębokiego (ang. deep learning)

Praca [12] dotyczyła dokładnego porównania klasyfikacji tkanek raka piersi za pomocą standardowego uczenia maszynowego opisanego w pracy [11] oraz uczenia głębokiego opisanego w pracy [8]. Dodatkowo policzono i porównano miary czułości, specyficzności i AUC (ang. area under curve) dla najlepszych klasyfikatorów w uczeniu maszynowym.

W klasyfikacji za pomocą sieci CNN uczenia głębokiego zastosowano dodatkowo dwa sztucznie wygenerowane kanały obrazów w odcieniach szarości. Była to nieujemna dekompozycja macierzy (ang. non-negative matrix factorization – NMF) oraz samopodobieństwo obrazu w sensie statystycznym (ang. self-similarity image). Schemat takiego działania przedstawiono na rysunku 12.



Rysunek 12. Schemat klasyfikacji raka piersi na podstawie zdjęć mammograficznych w uczeniu głębokim z użyciem dwóch dodatkowych sztucznych kanałów

Należy wspomnieć o nowym podejściu finałowego wyznaczania klasy. Procedura ta polegała na tym, że ciągły wynik klasyfikatora w procesie uczenia (jeszcze przed binaryzacją) poddano dynamicznemu wyznaczaniu nowego progu. Ustalony na końcowym etapie procesu uczenia nowy próg został zamrożony, a następnie wykorzystany przez walidację na niezależnym zbiorze próbek. Tabela 24 przedstawia najlepszy wynik uzyskany dla bazy danych DDSM z użyciem sieci CNN w uczeniu głębokim. Podczas testowania zbioru próbek używano 10-krotnej walidacji krzyżowej. Na podstawie tabeli 24 widać, że dokładność (ang. accuracy), czułość (ang. sensitivity) i specyficzność (ang. specificity) klasyfikacji zdrowej tkanki od tkanki nowotworowej (zmiana łagodna + zmiana złośliwa) były na wysokim poziomie i wynosiły odpowiednio 85,83%, 82,82% oraz 86,59%.

W pracy [12] pokazano ewidentną przewagę uczenia głębokiego nad uczeniem standardowym (uczenie maszynowe). Wszystkie miary jakości klasyfikacji znacząco wzrosły. Jednak zauważono, że niektóre podejścia z elementami uczenia maszynowego (podejście hybrydowe) znacząco podnosiły poziom klasyfikacji, aż uzyskano najlepszy rezultat w historii wyniku dla publicznego zbioru DDSM, gdyż bez tychże wskaźnik AUC spadł z 0,919 do wartości 0,88.

Janek levi

Tabela 24. Wyniki eksperymentu numerycznego rozpoznawania raka piersi z użyciem sieci CNN w uczeniu głębokim

Sensitivity	Specificity	Accuracy
82.82%± 0.95	86.59%± 1.12	85.83%± 1.08

Osiągnięciem naukowym przedstawionym w tej publikacji było opracowanie porównania skutecznej metodyki rozwiązania problemu diagnostycznego w postaci diagnostyki raka piersi na podstawie publicznie dostępnej bazy "Digital Database for Screening Mammography" (DDSM) za pomocą uczenia maszynowego oraz głębokiego. Na uwagę zasługuje nowatorskie podejście finałowego wyznaczania klasy, w postaci dynamicznego określenia progu klasyfikacji podczas uczenia, zamrożenie go, a następnie użycie tego progu we właściwym procesie klasyfikacji. Pozwoliło to na zwiększenie dokładności klasyfikacji.

9. Wnioski końcowe

Badania prowadzone przeze mnie dotyczą zastosowania metod sztucznej inteligencji w rozwiązywaniu zagadnień klasyfikacji w wybranych problemach diagnostycznych. Prowadzone przeze mnie prace można podzielić na następujące kategorie:

- opracowanie nowych deskryptorów numerycznych sygnałów czasowych, obrazów, danych finansowych,
- opracowanie nowych metod selekcji cech lub usprawnienie istniejących,
- zastosowanie uczenia maszynowego w wybranych problemach diagnostycznych,
- opracowanie architektur uczenia głębokiego w zastosowaniu do klasyfikacji w wybranych problemach diagnostycznych,
- opracowanie nowatorskich metod fuzji klasyfikatorów do pracy w zespole w zastosowaniu do klasyfikacji w wybranych problemach diagnostycznych,
- zastosowanie nieujemnej faktoryzacji macierzy (NMF) dla części obrazów „prawidłowych” do zwiększenia skuteczności klasyfikacji,
- generacja sztucznych kanałów w obrazach szarościowych do zwiększenia dokładności klasyfikacji za pomocą sieci CNN uczenia głębokiego,
- generacja samopodobieństwa rozkładów obrazów pozwalająca na precyzyjniejsze uchwycenie cech diagnostycznych,
- opracowanie modelu diagnostycznego raka jasnokomórkowego nerki,
- opracowanie podejścia do rozpoznawania czerniaka na podstawie niepowiększonych zdjęć zmian skórnych,
- opracowanie modelu diagnostycznego rozpoznania czerniaka na podstawie zdjęć dermatoskopowych zmian skórnych.
- opracowanie nowatorskiego podejścia wyznaczania klasy, w postaci dynamicznego określenia progu klasyfikacji podczas procesu uczenia.

Jan Łew