

dr inż. Krzysztof Damian Przybył
Katedra Mleczarstwa i Inżynierii Procesowej
Wydział Nauk o Żywności i Żywieniu
Uniwersytet Przyrodniczy w Poznaniu

AUTOREFERAT

prezentujący opis osiągnięć i dorobku naukowo-badawczego



1. Dane osobowe

Krzysztof Damian Przybył

Uniwersytet Przyrodniczy w Poznaniu

Wydział Nauk o Żywności i Żywieniu

Katedra Mleczarstwa i Inżynierii Procesowej



ORCID

0000-0002-2535-8370



Web of Science ResearcherID

AAH-1822-2020



Scopus AuthorID

57190815187

2. Posiadane dyplomy i stopnie naukowe

- 2015 doktor w dziedzinie nauk rolniczych, dyscypliny inżynierii rolniczej. Wydział Rolnictwa i Bioinżynierii, Uniwersytet Przyrodniczy w Poznaniu, tytuł rozprawy doktorskiej: „Klasyfikacja uszkodzeń ziemniaków w procesie przechowywania za pomocą analizy obrazu”. Promotor: prof. dr hab. inż. Piotr Boniecki, promotor pomocniczy: dr hab. inż. Krzysztof Koszela
- 2011 magister inżynier w zakresie informatyki w inżynierii rolniczej. Wydział Rolnictwa i Bioinżynierii, Uniwersytet Przyrodniczy w Poznaniu, tytuł zawodowy: magister inżynier (ocena z pracy dyplomowej: 5.0). Temat pracy magisterskiej: „Zastosowanie sieci neuronowej typu Kohonena jako klasyfikatora bezwzorcowego w wybranych zagadnieniach inżynierii rolniczej”. Promotor dr hab. inż. Piotr Boniecki.

3. Informacja o dotychczasowym zatrudnieniu w jednostkach naukowych

- 09/2021 – obecnie praca na stanowisku adiunkta, Katedra Mleczarstwa i Inżynierii Procesowej, Wydział Nauk o Żywności i Żywieniu, Uniwersytet Przyrodniczy w Poznaniu.
- 09/2015 – 08/2021 praca na stanowisku adiunkta, Instytut Technologii Żywności Pochodzenia Roślinnego, Wydział Nauk o Żywności i Żywieniu, Uniwersytet Przyrodniczy w Poznaniu.
- 10/2012 – obecnie praca na stanowisku informatyka, Biblioteka Uniwersytetu Przyrodniczego w Poznaniu.

4. Działalność naukowo-badawcza

4.1. Tytuł osiągnięcia naukowego

Osiągnięciem, będącym podstawą do ubiegania się o stopień naukowy doktora habilitowanego jest cykl pięciu powiązanych tematycznie prac ujętych pod wspólnym tytułem:

Metody sztucznej inteligencji do oceny parametrów jakościowych proszków z wybranych owoców jagodowych

Publikacje wchodzące w skład ww. osiągnięcia sztucznej inteligencji jako narzędzia wspomagającego ocenę jakości i rozpoznawania proszków z wybranych owoców, z wykorzystaniem zaawansowanych algorytmów SI (Sztucznej Inteligencji), takich jak sieci neuronowe i zespoły klasyfikatorów, aby poprawić procesy produkcyjne i kontrolę jakości w technologii żywności. W skład ww. osiągnięcia wchodzi następujące pozycje:

- 4.1.1.** Przybył, K., Samborska, K., Koszela, K.*, Masewicz, Ł., Pawlak, T. (2021). Artificial neural networks in the evaluation of the influence of the type and content of carrier on selected quality parameters of spray dried raspberry powders. *Measurement*, 186, 110014. <https://doi.org/10.1016/j.measurement.2021.110014> [200 pkt MNiSW/MEiN, IF₂₀₂₁=5.131, IF_{5-letni}=5.0, Cytowania WoS: 18, Scopus: 22].
- 4.1.2.** Przybył, K., Koszela, K.*, Adamski, F., Samborska, K., Walkowiak, K., Polarczyk, M. (2021). Deep and Machine Learning Using SEM, FTIR, and Texture Analysis to Detect Polysaccharide in Raspberry Powders. *Sensors*, 21(17), 5823. <https://doi.org/10.3390/s21175823> [100 pkt MNiSW/MEiN, IF₂₀₂₁=3.847, IF_{5-letni}=4.1, Cytowania WoS: 21, Scopus: 25].
- 4.1.3.** Przybył K., Walkowiak K., Jedlińska A., Samborska K.*, Masewicz Ł., Biegalski J., Pawlak T., Koszela K. (2023). Fruit powders analysis using machine learning based on color and FTIR-ATR spectroscopy. Case study: black currant powders. *Applied Sciences*, 13(5), 2965. <https://doi.org/10.3390/app13169098> [100 pkt MNiSW/MEiN, IF₂₀₂₃=2.5, IF_{5-letni}=2.7, Cytowania WoS: 4, Scopus: 4].

- 4.1.4.** Przybył, K.*, Walkowiak, K., Kowalczewski P.Ł. (2024). Efficiency of identification of blackcurrant powders using classifier ensembles, *Foods* 13(5), 697. <https://doi.org/10.3390/foods13050697> [100 pkt MNiSW/MEiN, IF₂₀₂₃=4.7, IF_{5-letni}=5.1, Cytowania WoS: 1, Scopus: 1].
- 4.1.5.** Przybył K*. (2024). Explainable AI: Machine Learning Interpretation in Blackcurrant Powders, *Sensors* 24(10), 3198. <https://doi.org/10.3390/s24103198> [100 pkt MNiSW/MEiN, IF₂₀₂₃=3.4, IF_{5-letni}=3.7, Cytowania WoS: 0, Scopus: 0].

Mój wkład w wyżej wymienione publikacje obejmował: autorstwo hipotez i koncepcji badań, udział w wykonaniu doświadczeń, analizę i opracowanie wyników (w tym wykonanie modeli neuronowych), wnioskowanie, napisanie artykułów w wersji pierwotnej, opracowanie wszystkich recenzji oraz redagowanie manuskryptów do druku (załączono oświadczenia współautorów). Ponadto, 1 z 5 prac (4.1.5) to praca mono autorska, a w przypadku 2 z 5 (4.1.4 i 4.1.5) prac pełniłem także funkcję autora korespondencyjnego.

Łączna punktacja prac zgłoszonych do oceny w postępowaniu habilitacyjnym:

- **Sumaryczny Impact Factor: 19,578⁽¹⁾; 20,6⁽²⁾.**
- **Liczba punktów wg MNiSW: 600⁽³⁾**

⁽¹⁾ – Sumaryczny impact factor (IF) obliczono wg bazy Journal Citation Reports, sumując współczynniki z roku wydania publikacji. Publikacjom przypisano oznaczenia porządkowe **4.1.1 – 4.1.5** zgodne z wykazem osiągnięć naukowych stanowiących znaczny wkład w rozwój dyscypliny technologia żywności i żywienia (**Załącznik 4: poz. I.2.1 – 2.5**).

⁽²⁾ – Średni pięcioletni Impact Factor.

⁽³⁾ – Punkty za publikacje naliczone zgodnie z komunikatem Ministra Nauki i Szkolnictwa Wyższego w oparciu o rok wydania tych publikacji.

Część wyników przedstawionych w wyżej wymienionych publikacjach jest rezultatem badań realizowanych w ramach zadania badawczego **MINIATURA 5 o numerze **2021/05/X/NZ9/01014** (**Załącznik 4: poz. II.9.2**) przyznanego przez Narodowe Centrum Nauk, którego byłem **kierownikiem**.**

4.2.Omówienie celu naukowego ww. prac i osiągniętych wyników oraz ich wykorzystanie

4.2.1. Wprowadzenie

Zagadnienia badawcze omawiane w trakcie pracy doktorskiej znacząco wpłynęły na dalszy kierunek mojej kariery naukowej określając przy tym główne obszary, na których skoncentrowałem się w mojej dotychczasowej działalności badawczej. Główne zainteresowania naukowo-badawcze skupiłem na takich obszarach jak: sztuczna inteligencja, ocena jakości produktów rolno-spożywczych z wykorzystywaniem nowoczesnych metod analitycznych poprawiając jakość i bezpieczeństwo żywności.

Inteligencja ludzka niewątpliwie od lat stanowiła źródło fascynacji i licznych badań [Kim H. i wsp. 2022]. Prowadzone działania badawcze nad inteligencją ludzką pozwoliły odkrywać wiele aspektów opierających na emocjach, kreatywności, zdolnościach poznawczych wpływając na rozwój edukacji i technologii. Naukowcy dążą do ciągłego rozwiązywania złożonych problemów, starając się dogłębnie analizować zrozumieć abstrakcyjne pojęcia [Bostrom N. 2014]. Wykonując analizę i rozważanie na poziomie abstrakcyjnym odkrywają ukryte wzorce (zależności) oraz poszukają szybkich i skutecznych odpowiedzi na szereg pytań. W wyniku tego działania gromadzą bazę wiedzy w oparciu o opinie i doświadczenia, opracowują nowe technologie oraz wykorzystują metody do wspomagania pracy z otoczeniem. Te badania mechanizmów ludzkiej inteligencji wpłynęły na powstanie dziedziny nauki zwanej sztuczną inteligencją (SI) [Bostrom N. 2014].

Sztuczna inteligencja wg McCarthy’ego to inteligencja wykazywana przez urządzenia sztuczne (w przeciwieństwie do inteligencji naturalnej) [Dietterich T.G. 2017]. Sztuczna inteligencja wg Mińskiego opiera koncepcję na maszynach realizujących zadania wymagające inteligencji ludzkiej [Dietterich T.G. 2017]. Natomiast w teorii Edwarda Feigenbauma obejmuje ona metody i techniki wnioskowania komputerowego, które pozwalają na reprezentację i wykorzystanie pozyskanej wiedzy [Grier D.A. 2013]. Sztuczna inteligencja definiowana przez Tadeusiewicza określana jest przez pozyskiwanie wiedzy informatycznej, pozwalającej budować programy komputerowe, które wykonują takie działania, które – gdy są wykonywane przez człowieka – są oceniane jako działania inteligentne [Tadeusiewicz R., 1995]. W mojej ocenie do zdefiniowania sztucznej inteligencji można by użyć stwierdzenia, że to algorytm przetwarzający informację pozyskaną z otoczenia z zamiarem wykorzystania do podejmowania problemów decyzyjnych, aby z pewnym oszacowaniem osiągnąć założony cel [Bostrom N. 2014, Patterson J. i wsp. 2017].

SI jest szeroko stosowana w różnych dziedzinach, począwszy od przemysłu poprzez produkcję żywności, inżynierię, medycynę, aż po rolnictwo. W technologii żywności SI znalazła zastosowania m.in. w celu utrwalania produktu spożywczego, uskuteczniania procesów jednostkowych poprzez automatyzację czy też monitorowanie surowca lub otrzymywanego produktu końcowego. Metody sztucznej inteligencji pozwalają m.in. ocenić jakość pobranych próbek żywności poprzez ich klasyfikowanie oraz prognozowanie m.in. etapów produkcji żywności. Wspomaganie procesów technologicznych za pomocą SI może prowadzić do zwiększenia wydajności otrzymywanych surowców, przez co poprawi działania w celu zautomatyzowania m.in. oceny jakościowej surowca, niebawem także możliwe w czasie rzeczywistym (on-line). Wobec tego, poszukuje się odpowiednich metod wspomagających bezpieczeństwo mikrobiologiczne do obecnie opracowywanych produktów żywnościowych, optymalizuje się wykonywanie wielu codziennych zadań, co przekłada się na zwiększenie efektywności procesów oraz bezpieczeństwo i trwałość żywności. To SI przy pomocy metod takich, jak: drzewa decyzyjne [Kavdir I. i wsp. 2004], sztuczne sieci neuronowe [Tadeusiewicz R. 1994], systemy ekspertowe [Przybył K., Ryniecki A. i wsp. 2016], uczenie maszynowe [Hameed K. i wsp. 2018], modele hybrydowe [Adnan R.M. i wsp. 2021], interpretacja danych, widzenie komputerowe czy przetwarzanie języka naturalnego możliwe, że wpłynie na tworzenie coraz bardziej złożonych i zaawansowanych zastosowań. Przy pomocy algorytmów uczenia maszynowego i analizy danych, możliwe staje się wspomaganie procesów technologicznych eliminując straty, a przy tym zwiększając wydajność w produkcji.

Obecnie na popularności zyskało tzw. uczenie maszynowe (ang. Machine Learning, ML). Zagadnienie związane z uczeniem maszynowym oparto na zastosowaniu komputerów, które mogą analizować dane oraz projektować modele adekwatne do nieustannie stawianych zjawisk, jak i wymagań. Algorytmy uczenia maszynowego mogą być wykorzystane do przewidywania jakości, jak i trwałości produktów żywnościowych, np. poprzez analizę obrazów, tekstur i innych danych sensorycznych w celu zidentyfikowania wad [Bengio Y. 2009]. ML może być zastosowane do identyfikacji, usuwania skażeń, zanieczyszczeń, monitorowania i realizowania przepływu danych w produkcji przemysłowej między różnymi maszynami, tj. ich czujnikami i przetwarzaniem w chmurze oraz będzie analizować dużą ilość generowanych danych sugerując kombinacje i proporcje składników w celu wytworzenia nowych ulepszonych produktów spożywczych.

Kolejny krok ML, poprzez wspomniane wcześniej działania, wdroży algorytmy w przetwórstwie spożywczym (Przemysł 4.0). W wyniku zaawansowanych systemów monitorowania jakości i okresu przydatności do spożycia w produkcji i dystrybucji żywności

przemysł stanie się bardziej elastyczny, co przełoży się na optymalizację produkcji ograniczając przy tym straty pozyskiwanego produktu spożywczego. Przyszłość opiera się na autonomiczności maszyn (przemysł 5.0), które będą zarządzać sterowaniem procesów produkcji, jak i dystrybucją żywności. Efektywnie oceniać trwałość każdego produktu żywnościowego w trakcie, jak i już po jego wyprodukowaniu, wykorzystując zaawansowane algorytmy uczenia maszynowego, eliminując opóźnienia, koszty i błędy ludzkie.

Dzisiejsza inteligentna rzeczywistość proponuje rozwiązania z wykorzystaniem także głębokiego uczenia do rozpoznawania, identyfikowania, transkrypcji, optymalizowania oraz przewidywania stawianych problemów. Kluczowym zagadnieniem głębokiego uczenia coraz częściej jest metoda oparta na rozpoznawaniu obrazów lub mowy. Obecnie zaawansowane modele głębokiego uczenia skupiają się głównie na klasyfikowaniu obiektów przy pomocy piksela obrazu na zdjęciach cyfrowych (tzw. widzenie komputerowe). Głębokie uczenie (ang. Deep learning, DL) to jedna z podkategorii uczenia maszynowego. Istota działania polega na stworzeniu sztucznych sieci neuronowych, których celem jest udoskonalenie np. rozpoznawania obrazu (powszechnie stosowanym również w żywności) [**Krohn J. i wsp. 2020**].

Proces uczenia jest z definicji określany jako głęboki, ponieważ struktura sztucznych sieci neuronowych składa się z wielu warstw wyjściowych, wejściowych i ukrytych. Każda z warstw zawiera też jednostki, które przekształcają dane wejściowe w informacje, których następne warstwy mogą używać do wykonania zadania predykcyjnego. W ten sposób, maszyna uczy się za pomocą własnego przetwarzania danych. Zastosowanie głębokiego uczenia w technologii żywności kluczowe znaczenie ma podkategoria dotycząca analizy i rozpoznawania obrazu.

Mając na uwadze sezonowość owoców ogromne znaczenie mają wszelkie metody utrwalania pozwalające na przedłużenie ich trwałości. Wobec tego coraz aktywniej poszukuje się metod wspomagających utrwalanie żywności, szczególnie dla tej bogatej w wartości odżywcze kategorii produktowej [**Hameed K. i wsp. 2018**]. W istocie odpowiednie utrwalanie żywności pozwoli na utrzymywanie zawartości związków bioaktywnych w owocach oraz zachowa wysoki współczynnik jakości.

Owoce są podstawowymi składnikami prozdrowotnymi w diecie człowieka, czego potwierdzeniem jest łatwe ich przyswajanie w organizmie [**Liu R.H. 2013**]. Dostarczają dużo składników odżywczych niezbędnych do prawidłowego funkcjonowania organizmu (węglowodany, białko, witaminy) [**Fenech i wsp., 2019**], ale także składniki mineralne, błonnik, antyoksydanty czy wodę [**Kader A.A. 2008, Liu R.H. 2013**]. Zalecane jest również

spożywanie ich przynajmniej 400 g/dziennie [Banaś A., 2018]. Owoce są bardzo atrakcyjne jako surowiec do bezpośredniego spożycia, jak i do przerobu ze względu na budowę oraz atrakcyjne walory sensoryczne. Stwierdzono, że dieta oparta na spożywaniu większych ilości owoców i warzyw ma wpływ na obniżenie ryzyka zachorowania na m.in. cukrzycę, nadciśnienie czy nadwagę.

Warto mieć na uwadze, że zmiany przemiany metabolicznej owoców uzależnione są od działania wysokiej temperatury. Owoce pozostawione już w temperaturze pokojowej pogorszą swój turgor przez degradację związków (m.in. w procesie utleniania), zwiększenie wilgotności i aktywności wody prowadząc nawet do zepsucia mikrobiologicznego.

W pracy badawczej skoncentrowałem się na analizie owoców jagodowych. Produkcja owoców jagodowych w Polsce ogólnie ma tendencję wzrostową. W 2020 roku zbiór owoców z krzewów owocowych w sadach i na plantacjach jagodowych wynosił powyżej 0,5 mln ton, czyli o ponad 10% więcej niż w 2019 roku [GUS, 2020]. W 2022 roku szacuje się na przeszło 0,6 mln ton, czyli o ponad 5% więcej niż w roku 2021 [GUS, 2022]. Zbiory malin zostały oszacowane nieznacznie powyżej 110 tys. t., tj. o ok. 6% więcej od ubiegłorocznych [GUS, 2022]. Zbiory porzeczek czarnych zostały ocenione na niespełna 105 tys. t., tj. o ok. 9% mniej niż w 2021 roku [GUS, 2022]. Szacuje się, że produkcja truskawek wyniosła ok. 184 tys. ton, co wyznacza wzrost o 18% w porównaniu do ubiegłego roku. Zbiory agrestu wynosiły ok. 9 tys. ton, czyli o 5% mniej niż w poprzednim roku. Ogólnie produkcję innych owoców z krzewów owocowych i na plantacji jagodowych w sadach wyniosła prawie 77 tys. ton, czyli o 6% mniej niż w 2021 roku [GUS, 2022].

Zainteresowanie owocami jagodowymi wynika z ich potencjału prozdrowotnego. Maliny i porzeczki to cenne źródło związków bioaktywnych. Czerwone maliny (*Rubus idaeus* L.) zawierają różnorodne składniki odżywcze i fitochemiczne ważne dla zdrowego stylu życia [Burton-Freeman B.M. i wsp. 2016]. Zalecane jest spożywanie malin ze względu na ich składniki odżywcze [Xu Y. i wsp. 2019], a także wspomagająco w okresie przeziębienia, ponieważ działają rozgrzewająco na organizm wywołując m.in. proces pocenia się. Potwierdzono także, że składniki odżywcze zawarte w malinach pomagają w walce z otyłością [Luo T. 2016], cukrzycą, nadciśnieniem oraz miażdżycą [Burton-Freeman B.M. i wsp. 2016]. Natomiast czarna porzeczka (*Rubus nigrum* L.) zawiera kwasy fenolowe, flawonoidy i antocyjany. Czarne porzeczki są źródłem wielu witamin, m.in. witaminy C. W literaturze wykazano, że wpływają na metabolizm tłuszczów oraz zdolność do regulowania funkcji układu odpornościowego [Alzahrani M.A. i wsp. 2023].

Wobec potencjału zdrowotnego oraz zapobiegania przemianom metabolicznym (wyeliminowanie ich zepsucia, rozwoju bakterii oraz innych drobnoustrojów), szczególnie przy tych owocach zbieranych sezonowo poszukuje się odpowiedniej metody w celu utrwalania ich stanu jakościowego i wydłużenia okresu przydatności do spożycia [**Ahmed N. i wsp. 2013**, **Karam M.C. i wsp. 2016**]. Kluczowym aspektem okazuje się być kontrola zawartości wody w owocach wydłużając ich okres trwałości podczas przechowywania.

Wśród tych metod, które mogą ingerować na zawartość wody w owocach, nie wpływając na proces degradacji związków bioaktywnych, zalicza się suszenie, które poza utrwaleniem prowadzi również do otrzymania korzystnej formy, łatwej do zastosowania w wielu ostatecznych produktach. Suszenie pozwala zahamować przemiany fizykochemiczne, przekładając się na utrzymanie stanu jakościowego wysuszonego surowca [**Xu Y. i wsp. 2019**]. Niemniej produkt otrzymany w wyniku suszenia może uzyskać niekorzystne zmiany strukturalne (objętość, porowatość, gęstość), sensoryczne (smak, zapach), teksturalne, odżywcze czy optyczne (wygląd, barwa).

Suszenie stało się popularne w przemyśle spożywczym, szczególnie dla potrzeb utrwalania w ostatnim etapie produkcji. Najczęściej stosuje się suszenie rozpyłowe. Metoda ta polega na suszeniu produktów płynnych w celu uzyskania proszku w jednej krótkiej operacji i stosunkowo krótkim kontakcie produktu z czynnikiem grzewczym. Podstawową zasadą procesu suszenia rozpyłowego jest zwiększenie powierzchni parowania suszonej rozpyłowo cieczy, skutkiem czego występuje szybkie odprowadzenie wody w postaci pary. Aby znacząco zwiększyć powierzchnię parowania cieczy rozpyła się ją otrzymując mgiełkę złożoną z kropeł w zakresie 10-300 μm . Krótki czas odparowywania wody otrzymuje się dzięki wysokiej temperaturze powietrza suszącego. Czas suszenia wynosi 1-20 s [**Samborska K. 2010**]. Obecnie suszenie rozpyłowe znalazło zastosowanie w przypadku artykułów spożywczych występujących w postaci roztworów i zawiesin, w tym mleka [**Samborska K. 2019**], soków i koncentratów owocowych np. truskawki [**Przybył K. i wsp. 2018**], aronii [**Przybył K. i wsp. 2019**], rabarbaru [**Przybył K. i wsp. 2023**], maliny [**Przybył K. i wsp. 2021**] (I.2.1) oraz czarnej porzeczki [**Przybył K. i wsp. 2023**] (I.2.3).

Suszenie mokrych surowców to złożony a zarazem dynamiczny, wysoce nieliniowy proces termiczny, dla którego podstawowe mechanizmy nie są jeszcze dokładnie poznane. Złożoność tego procesu wzrasta jeszcze bardziej, gdyż wynika z szeregu czynników m.in. równoczesnego stanu nieustalonego, zmiany ciepła i masy, przemian fazowych, reakcji fizykochemicznych, reakcji zmienności surowca w czasie, zmian strukturalnych suszonego produktu oraz gwałtownego twardnienia powierzchni surowca. Co więcej, w typowym procesie

suszenia, niektóre kluczowe parametry, takie jak warunki suszenia oraz skład produktu, regulują jakość gotowego produktu. Zatem kontrola jakości odgrywa kluczową rolę w suszeniu oraz technologii oceny produktu suszonego do spożycia lub dalszego przetwarzania [Rad M.R.N. 2015]. Wobec tego, poszukiwanie efektywnego modelowania, prowadzenie szeregu symulacji, dokonywanie przewidywania, optymalizacji, prowadzenia kontroli jakości, wykrywania wzorców i diagnozowania systemów suszenia to krytyczne aspekty technologii suszenia. Inżynierowie, projektanci czy badacze poszukują optymalnej metody suszenia dla wskazanego produktu tj. proszków spożywczych, aby wykonać projekt oraz adekwatnie dostosować parametry pracy suszarek na skalę przemysłową, co w konsekwencji ma wpłynąć na zmniejszenie kosztów operacyjnych oraz energii, zarazem zwiększając tempo produkcji, a nawet da możliwość ulepszenia dostępnego systemu suszenia.

Zrozumienie i modelowanie wszystkich tych relacji ma znaczenie w technologii suszenia w celu spełnienia wymagań dotyczących konsumpcji lub dalszego przetwarzania. Jednakże, identyfikacja relacji między wejściami a wynikami procesu suszenia za pomocą matematycznych, statystycznych danych analitycznych może stać się znacznie bardziej kłopotliwe lub nawet czasem niemożliwe [Samborska K. 2008]. Niemniej jednak heurystyczne metody obliczeniowe, takie jak sztuczne sieci neuronowe, stanowią obiecujące alternatywy do radzenia sobie z nieliniowością i złożonością problemów. Sztuczne sieci neuronowe są szczególnie przydatne w sytuacjach, gdy wyniki procesu są trudne do zdefiniowania lub wyjaśnienia. Prognozowanie na podstawie danych historycznych umożliwia kontrolowanie zachowania mechanizmów i systemów produkcji żywności [Sejnowski T.J. i wsp. 2019].

W związku z powyższym w badaniach skoncentrowałem się na opracowaniu nowatorskich technik przy pomocy metod sztucznej inteligencji w ocenie jakości proszków z soków malinowego i porzeczkowego [I.2.1, I.2.2, I.2.3, I.2.4, I.2.5] wykorzystując przy tym techniki obrazowania oraz analizy fizyczne.

4.2.2. Cel naukowy osiągnięcia oraz omówienie wyników badań

Zastosowanie metod sztucznej inteligencji w produkcji i dystrybucji żywności staje się powszechniejsze i przynoszące liczne korzyści. Zaawansowane techniki uczenia maszynowego i głębokiego pozwalają skuteczniej zarządzać surowcem, wodą i energią przy procesie otrzymywania oraz przetwarzania tych surowców. Wykorzystywanie sztucznej inteligencji pozwala na dokładne monitorowanie i kontrolowanie stanu jakościowego produktów spożywczych na różnych etapach produkcji. Przy pomocy uczenia maszynowego i głębokiego możliwe staje się analizowanie odpowiednio przygotowanych parametrów fizycznych oraz

wzorców obrazów. Zaprojektowane sztuczne sieci neuronowe mogą posłużyć do wykrywania zanieczyszczeń, wad oraz innych problemów jakościowych w ramach bezpiecznej i wysokiej jakości żywności.

W ramach mojego osiągnięcia naukowego głównym celem badań było poznanie związku pomiędzy morfologią mikrocząstek a stanem jakościowym proszków owocowych otrzymanych w procesie suszenia rozpyłowego. Istotnie dane opierały się głównie na pozyskanych parametrach w wyniku metod fizycznych (aktywność wody, kolorymetria, spektroskopia FTIR-ATR), komputerowej analizy obrazu oraz techniki obrazowania tj. mikroskopii elektronowej.

Analiza morfologii mikrocząstek to skomplikowany i czasochłonny proces. Pozyskiwanie struktury morfologicznej mikrocząstek na podstawie zdjęć cyfrowych pozwala SI na szybsze przetwarzanie ogromnych ilości danych. Ręczne przetwarzanie danych staje się dość trudne, a nawet mało skuteczne. W związku z tym uzasadnione jest zastosowanie metod sztucznej inteligencji, które umożliwią przyspieszenie i ułatwienie rozpoznawania morfologii mikrocząstek za pomocą deskryptorów obrazu, co pozwoli na osiągnięcie wysokiego wskaźnika dokładności w identyfikacji tego typu produktów spożywczych. W osiągnięciu naukowym wykorzystano różne techniki sztucznej inteligencji przy identyfikacji oraz ocenie jakości proszków owocowych, ze szczególnym uwzględnieniem proszków z soków malinowego i porzeczkowego (czerwonej maliny i czarnej porzeczki). Celem użytecznym było opracowanie efektywnych narzędzi do nieinwazyjnego rozpoznawania oraz analizy jakości wybranych proszków owocowych.

W związku z powyższym sformułowano następujące hipotezy badawcze:

- 1. Zmiany w doborze nośnika oraz w wielkości mikrocząstek proszków z soku malinowego wpływa na ich właściwości fizyczne tj. aktywność wody, wilgotność oraz kształt mikrocząstek.**
- 2. Głębokie uczenie z wykorzystaniem sieci konwolucyjnych (CNN), sieci neuronowe typu Multi-Layer Perceptron (MLP) oraz spektroskopia fourierowska w podczerwieni (FTIR) pozwalają na ocenę jakościową proszków owocowych.**
- 3. Metody uczenia maszynowego i analiza FTIR pozwalają na rozpoznawanie siły barwienia w proszkach owocowych, biorąc pod uwagę ilość oraz rodzaj nośnika zawartego w roztworze owocowym.**
- 4. Meta klasyfikator oraz zespoły klasyfikatorów poprawiają skuteczność identyfikowania struktury morfologicznej proszków z soku porzeczkowego przy pomocy tekstury obrazu (ang. Gray-Level Co-occurrence Matrix, GLCM).**

5. Wykorzystanie modelu agnostycznego (ang. Local Interpretable Model agnostic Explanations, LIME) umożliwi zinterpretować typy proszków z soku owocowego na podstawie cech tekstury obrazu (GLCM).

Proces weryfikacji poszczególnych hipotez badawczych polegał na realizacji badań, w ramach których wyznaczono następujące cele:

- Ocena różnic w wielkości mikrocząstek wybranych rodzajów proszków z soku malinowego z wykorzystaniem skaningowej mikroskopii elektronowej (SEM), analiz fizycznych (aktywność wody i wilgotność) oraz sztucznych sieci neuronowych typu MultiLayer Perceptron (4.4.1).
- Określenie wpływu ilości i rodzaju nośnika zawartego w roztworze malinowym z wykorzystaniem CNN, sieci neuronowych typu MultiLayer Perceptron oraz spektroskopii fourierowskiej w podczerwieni (4.4.2).
- Ocena różnic w sile barwienia proszków z soku porzeczkowego z wykorzystaniem algorytmów uczenia maszynowego oraz spektroskopii fourierowskiej w podczerwieni (4.4.3).
- Ocena stanu jakościowego proszków porzeczkowych z wykorzystaniem tekstury obrazu (GLCM) i określenie skuteczności rozpoznawania tych proszków z wykorzystaniem uczenia maszynowego (zespołów klasyfikatorów) (4.4.4).
- Interpretacja podejmowania decyzji przez algorytmy uczenia maszynowego w ramach rozpoznawania typów proszków z soku porzeczkowego wspomagane Local Interpretable Model-agnostic Explanations (4.4.5).

Ad. 4.4.1. Artificial neural networks in the evaluation of the influence of the type and content of carrier on selected quality parameters of spray dried raspberry powders – publikacja 1 (I.2.1).

W ramach pracy zwróciłem uwagę na ocenę wpływu nośnika (przy zachowaniu tych samych parametrów suszenia rozpyłowego) na wybrane właściwości fizyczne proszków z soku malinowego. Materiały bogate w cukier, takie jak soki owocowe, są produktami bardzo trudnym do bezpośredniego suszenia rozpyłowego, bez wykorzystania nośnika [Shishir M.R. i Chen W. 2017, Quek N.K. i wsp. 2007]. Nośniki pozwalają bowiem na zwiększenie temperatury przemiany szklistej oraz wydajności, co przekłada się na zmniejszenie lepkości oraz poprawę kohezji sproszkowanego produktu [Etzbach M. i wsp. 2020]. Dodatki w postaci nośników zapobiegają również wywołaniu niepożądanego zjawiska kleistości [Igual M. i wsp. 2014, Truong V., Bhandari T. i wsp. 2005]. W ostatnich latach opracowano nowe

podejście w suszeniu rozpyłowym, które pozwala jednocześnie obniżyć temperaturę suszenia, zawartość nośnika i zwiększyć odzysk proszku [**Jedlińska A., Samborska K i wsp. 2019, Samborska K. 2019**].

Wobec powyższego, pożądanym byłoby wprowadzenie nowatorskiej techniki przy pomocy metod sztucznej inteligencji w ocenie jakości tych proszków [**Przybył K. i wsp. 2018**]. W pracy przeprowadziłem porównanie i ocenę wybranych nośników ze względu na właściwości fizyczne otrzymanych proszków z soku malinowego. Rozpoznawanie każdej próby proszków z soku malinowego wykonałem na podstawie różnego udziału ilości nośnika oraz ze względu na aktywność wody, wilgotność oraz mikrostrukturę mikrocząstek. Identyfikację prób proszków owocowych wykonałem przy użyciu techniki wizyjnej wspomaganej sztucznymi sieciami neuronowymi. Zaprojektowałem model neuronowy w celu klasyfikowania prób proszków z soku malinowego, które różnią się zarówno doбором nośnika (pośrednio mający wpływ na aktywność wody, wilgotność), jak i mikrostrukturą (pośrednio mający wpływ na kształt mikrocząstek).

W pracy wchodzącej w skład osiągnięcia najpierw przygotowałem 9 wariantów roztworów owocowych. Następnie brałem udział w suszeniu tych roztworów m.in. w ramach miesięcznego stażu naukowego w Szkole Głównej Gospodarstwa Wiejskiego (SGGW) w Warszawie (Załącznik 4: **poz. II.11.2**).

Kolejne etapy wymagały wykonania analiz fizycznych dla pozyskanych proszków z soku malinowego. Określiłem wilgotność proszków z dokładnością oznaczania zawartości wody 0,05%. Wyznaczyłem wraz z zespołem aktywność wody przy użyciu analizatora dyfuzji i aktywności wody ADA-7 (COBRABID, Poznań) z systemem automatycznej rejestracji czasu przebiegów ewakuacji wody dla poszczególnych próbek. W kolejnym etapie wykonałem zdjęcia cyfrowe proszków z soku malinowego przy pomocy skaningowej mikroskopii elektronowej (SEM) w ramach stażu naukowego w SGGW w Warszawie (Załącznik 4: **poz. II.11.2**).

Następnie, przygotowałem dane cyfrowe dla utworzenia zbioru danych (zbioru uczącego). Pozyskałem 9 obrazów o rozdzielczości 1024x1088, głębi bitowej 32-bit oraz zapisanych w formacie „TIFF”, odpowiadających za rodzaj proszków z soku malinowego. Wykonałem z zespołem 10 powtórzeń otrzymując 90 zdjęć cyfrowych określające proszki z soku malinowego. Te badania również przeprowadziłem w laboratorium SGGW w Warszawie (Załącznik 4: **poz. II.11.2**).

W kolejnym etapie przygotowałem zbiór uczący. Pierwszy krok przy budowie zbiorów danych wymagał przystosowania próbki proszków z soku malinowego w taki sposób, aby

określić parametry fizyczne prób badawczych w postaci danych numerycznych. Za pomocą autorskiego oprogramowania „PIDsystem” (Przybył Image Detector system), wykonanego w ramach pracy doktorskiej, wykonałem kilka etapów przetwarzania i analizy obrazów mikroskopowych. Najpierw wykonałem wsadowe przycięcie obrazu do rozdzielczości 1024x1024 oraz 24-bitowej głębi obrazu. Wsadowe przycinanie obrazu w „PIDsystem” ma na celu zautomatyzowanie stawianego zadania. Następnie przeprowadziłem proces wykrywania krawędzi obrazu za pomocą metody Canny’ego, a potem powtórzyłem proces wykrywania zdjęć przy użyciu metody Sobela w „PIDsystem”. W efekcie otrzymałem zdjęcia o rozdzielczości 1024x1024 oraz 8-bitowej głębi obrazu. Ostatni etap przetwarzania obrazu wymagał utworzenia binaryzacji obrazu, aby otrzymać obrazy o rozdzielczości 1024x1024 oraz 1-bitowej głębi obrazu. Proces wyodrębniania cech reprezentatywnych dla mikrocząstek zbinaryzowanego obrazu wykonałem z wykorzystaniem programu ImageJ. W wyniku tego procesu otrzymałem deskryptory kształtu dla każdej mikrocząstki proszku takie jak: Area, Perimeter, Circularity (Circ.), Solidity, Round, Feret Diameter. Pozostałe parametry takie jak: wsp. Fereta (Feret Factor), współczynnik W1 i W2 wyznaczyłem w wyniku przekształceń matematycznych na podstawie wspomnianych wielkości. Feret Diameter opisuje średnicę cząstki, a wsp. Fereta miarę rozciągłości mikrocząstek w pionie i poziomie na podstawie (Feret Diameter), W1 wyznacza średnicę koła o obwodzie równym obwodowi analizowanej mikrocząstki a W2 wyznacza średnicę koła, którego pole równe jest polu analizowanej mikrocząstki. Do budowy zbioru uczącego określiłem jeszcze dwa znaczące parametry fizyczne takie jak: aktywność wody i wilgotność proszków z soku malinowego. Na rysunku 1 (I.2.1) przedstawiam algorytm pozyskania cech reprezentowanych w ramach budowy zbiorów Z1 i Z2. Zbiór uczący (Z1) zawiera 2902 przypadków uczących (tj. mikrocząstek) wyekstrahowanych z obrazu cyfrowego (po procesie binaryzacji) dla każdej z prób proszków z soku malinowego (9x1). Zbiór uczący (Z2) zawiera 31972 przypadków uczących wyodrębnionych z 10 obrazów cyfrowych (po etapie binaryzacji) dla każdej z prób badawczych (9x10).

W ramach uzyskanych wyników określających właściwości fizyczne proszków z soku malinowego zaobserwowałem, że najniższą wilgotność miały proszki z soku malinowego z dodatkiem inuliny. W odniesieniu do pozostałych prób badawczych szczególnie najniższa wilgotność występowała przy 30% udziale nośnika inuliny. Najwyższe wyniki wilgotności otrzymałem w przypadku proszków z dodatkiem gumy arabskiej, dla której wilgotność wynosiła prawie 7 razy więcej niż w przypadku proszku z dodatkiem inuliny. Powodem tak wysokiej wilgotności mogły być właściwości gumy arabskiej. Według **Ramakrishnan Y. i**

wsp. 2018 guma arabska jest złożonym heteropolisacharydem o rozgałęzionej strukturze i grupach hydrofilowych, co skutkuje wyższą zdolnością wiązania wody niż w przypadku innych nośników. Oznacza to, że guma arabska jako substancja powierzchniowo czynna zawierająca około 2% białka, może tworzyć warstwę powierzchniową utrudniającą odparowywanie wody. Przy suszeniu proszków z soku malinowego i różnym udziale nośnika gumy arabskiej nie stwierdziłem znaczącej zmiany wilgotności proszków. Warto zwrócić uwagę, że w wyniku redukcji ilości nośnika z 50% do 30% największe zmiany wilgotności podczas procesu suszenia z ok. 6% do ok. 1,5% występowały w proszkach z soku malinowego z nośnikiem maltodekstryny. Obniżenie o połowę wilgotności otrzymałem w przypadku dodatku inuliny. Takie zjawisko mogło być związane z łatwiejszą dyfuzją wody w mikrocząstkach o mniejszej zawartości składników wielkocząsteczkowych. W przypadku aktywności wody dla 9 wariantów proszków z soku malinowego zaobserwowałem, że najniższą aktywność wody otrzymałem w przypadku proszku z soku malinowego z dodatkiem 30% udziału inuliny jako nośnika. Można stwierdzić, że proszki z soku malinowego z dodatkiem inuliny wypadły przy ocenie znacznie korzystniej od pozostałych. To skutkuje potencjalnie wyższą trwałością mikrobiologiczną oraz lepszą rozpuszczalnością w wodzie dla proszków z soku malinowego z dodatkiem inuliny niż maltodekstryny czy gumy arabskiej. Jednakże, we wszystkich próbach badawczych zaobserwowałem, że wraz ze wzrostem wilgotności i aktywności wody zmniejsza się ich trwałość mikrobiologiczna zawartość wody. Zespół **Juarez-Enriquez i wsp. 2019** stwierdzili również, że aktywność wody w proszkach okazuje się być lepszym wskaźnikiem wpływu zawartości wody na stan jakościowy proszków niż zawartość wilgotności w proszku. Stwierdzono również, że zwiększenie aktywności wody może mieć wpływ na jakość proszków [**Perez-Reyes M.E. i wsp. 2021**]. Statystycznie potwierdziłem, że znaczącymi grupami okazały się próby proszków z soku malinowego, dla których uzyskano niższą aktywność wody oraz wilgotność [**Juarez-Enriquez i wsp. 2019, Hartman M. i wsp. 2011**]. Im bardziej zwiększał się udział nośnika tym grupy bardziej się od siebie różniły, co przekłada się na wyższą aktywność wody i zawartość wilgotności. Zauważyłem także, że ze względu na aktywność wody i wilgotność w próbach proszki z soku malinowego z dodatkiem inuliny nie różniły się od siebie znacząco. Z kolei, znaczące różnice zaobserwowałem przy wilgotności w przypadku proszków owocowych z udziałem maltodekstryny i gumy arabskiej.

Wykrywanie krawędzi z obrazu jest możliwe dzięki zaawansowanym technologiom analizy obrazu, które pozwalają precyzyjniej określić lokalizacje obiektów. W systemach wizyjnych metody wykrywania krawędzi pozwalają zminimalizować błędy przy wykrywaniu krawędzi oraz zapewniają dokładniejszą analizę lokalizacji pikseli krawędzi mikrocząstek. W

ramach wyników związanych z wykrywaniem krawędzi obrazu zaobserwowałem, że metoda Canny'ego pozwoliła zminimalizować błędy przy wykrywaniu krawędzi a wzbogacenie metodą Sobela pozwoliła skuteczniej rozpoznawać wielkości mikrocząstek proszków z soku malinowego. Moje doświadczenie uzyskane z wcześniejszych badań [Przybył K. i wsp. 2018] pozwoliło potwierdzić, że wskazane było w obecnych badaniach zastosowanie filtra Sobela, który pozwolił na uwypuklenie krawędzi każdej mikrocząstki proszku z soku malinowego. Rozpatrując wyniki wielkości mikrocząstek proszków z soku malinowego przy pomocy deskryptorów kształtu zaobserwowałem, że najmniejsze mikrocząstki otrzymano w proszkach z dodatkiem 30% maltodekstryny. Natomiast, największe mikrocząstki otrzymano w proszkach z 50% dodatkiem gumy arabskiej. Zaobserwowałem, że wraz ze zmniejszeniem ilości nośnika zmniejszała się wielkość mikrocząstek. Szczególnie to można zaobserwować w proszkach z dodatkiem gumy arabskiej. W badaniach dotychczas nie zaobserwowano wpływu kształtu mikrocząstek na warunki suszenia, ilość lub rodzaj nośnika w proszkach. Zaobserwowano jednak, że dobór warunków suszenia m.in. określona temp. i parametry zasilania wlotowego mogą mieć wpływ na wielkość mikrocząstek.

Na podstawie wyników metodą analizy głównych składowych (PCA) porównałem również wpływ współczynników kształtu na wielkość mikrocząstek proszków z soku malinowego uwzględniając 9 przeprowadzonych prób. Podobieństwo wektorów PCA wszystkich współczynników kształtu można zauważyć przy 50% i 60% udziale maliny z gumą arabską oraz maltodekstryną. W przypadku inuliny podobieństwo wektorów PCA przedstawiają wykresy odpowiednio odpowiadające 70% i 50% maliny. Zaobserwowałem, że pomiędzy grupami silnie korelują ze sobą współczynniki Circularity i Solidity. Rozpatrując te 2 współczynniki zauważyłem, że mikrocząstki w proszkach z soku malinowego wpływają na zmianę ich wielkości. Wraz ze zmniejszeniem udziału nośnika wzrasta wartość dla Circularity. Silną korelację zaobserwowałem także w próbach pomiędzy współczynnikiem Fereta a W2 (pośrednio oparty o obwód mikrocząstki). Im mniejszy udział nośnika tym mniejszy rozmiar mikrocząstki w oparciu o W2. Odnotowałem również, że występuje dodatni związek pomiędzy Circularity i Solidity w mikrocząstkach proszków z nośnikiem inuliny i można stwierdzić, że im mniejsza jest wartość Circularity tym większa wartość Solidity. W przypadku wyników za pomocą HCA potwierdziłem podobieństwo pomiędzy próbami badawczymi ze względu na rodzaj nośnika dodawanego do roztworu malinowego. Największe podobieństwo ze względu na miarę kształtu mikrocząstek występuje przy proszkach przy udziale 50% i 40% gumy arabskiej. Kolejne zależności co do struktury mikrocząstek zaobserwowałem pomiędzy proszkiem z soku malinowego z 30% udziałem gumy arabskiej a proszkami z soku malinowego

z 50% i 40% udziałem maltodekstryny. W przypadków proszków z soku malinowego z udziałem inuliny podobieństwo występuje pomiędzy różnym udziałem tego nośnika. Tym samym na podstawie HCA można stwierdzić, że podobieństwo w proszkach z soku malinowego występuje pomiędzy grupami z udziałem gumy arabskiej i maltodekstryny. Na podstawie literatury można zatem wnioskować, że to przekładać się może m.in. na ich dużą masę cząsteczkową, wysoką temperaturę zeszklenia (T_g) i dobrą rozpuszczalność oraz niską lepkość [Schutyser M.A.I i wsp. 2012, Shishir M.R.I i Chen W. 2017].

W ramach tych wyników otrzymałem dedykowane sieci neuronowe typu MultiLayer Perceptron, które osiągnęły skuteczność klasyfikacji proszków z soku malinowego na poziomie 0,99. Najniższy błąd Root Mean Square (RMS) [Bishop C.M.C.C.M. 2007, Niedbała G. 2019] na poziomie 0,0138 dla zbiorów: uczącego, testowego i walidacyjnego otrzymano dla sieci typu MLP o strukturze 8 zmiennych wejściowych (6 deskryptorów kształtu, aktywności wody oraz wilgotności) należącej do warstwy wejściowej, 44 neuronów w warstwie ukrytej oraz 9 neuronów w warstwie wyjściowej. Warstwa wyjściowa sieci określała zmienną 9-stanową tj. próby proszków spożywczych przy różnym udziale i rodzaju nośnika. Sieć MLP 8-44-9 wyznaczono ze zbioru pierwszego (Z1). Ze zbioru Z2 uzyskano sieć MLP 8-13-9 o strukturze tych samych parametrów w warstwie wejściowej i wyjściowej oraz 13 neuronów w warstwie ukrytej. Zastosowanie sztucznych sieci neuronowych wspomagane analizą obrazu umożliwiło skuteczną klasyfikację próbek proszku z soku malinowego na podstawie współczynników kształtu mikrocząstek proszku wraz z parametrami aktywności wody oraz wilgotności.

Ad. 4.4.2. Deep and Machine Learning Using SEM, FTIR, and Texture Analysis to Detect Polysaccharide in Raspberry Powders – publikacja 2 (I.2.2).

W ramach osiągnięcia naukowego wykorzystałem skaningową mikroskopię elektronową (SEM) [Przybył K. i wsp. 2021] (I.2.1), która obecnie zyskuje na popularności w zakresie rozpoznawania struktury morfologicznej żywności. Zaobserwowałem, że struktura morfologiczna mikrocząstek proszków owocowych pozwala na skuteczną ocenę ich jakości [Przybył K., Samborska K. i wsp. 2021, Przybył K. i wsp. 2018, Przybył K. i wsp. 2019, Przybył K., Gawalek J. i wsp. 2023] (I.2.1). W tych badaniach przeprowadziłem ocenę skuteczności przy pomocy Convolutional Neural Network, Multi-Layer Perceptron Network i metody FTIR w procesie identyfikacji dziewięciu prób badawczych proszków z soku malinowego na podstawie ilości i rodzaju nośnika. Utylitarnym celem badań było opracowanie modeli neuronowych zdolnych do szybkiego oraz bezinwazyjnego identyfikowania proszków owocowych otrzymywanych w procesie niskotemperaturowego suszenia rozpyłowego (tzn.

temperatura powietrza wlotowego wynosiła 80°C a wylotowego 50°C). Innowacyjność rozwiązania oparłem o technikę obrazowania SEM (pośrednio mający wpływ na teksturę i piksel obrazu) oraz widmo w funkcji absorbancji (FTIR).

W pracy wchodzącej w skład osiągnięcia naukowego najpierw pozyskałem próbki proszków z soku malinowego otrzymanych w wyniku suszenia rozpyłowego. Następnie wykonano obrazowanie, zrobiłem zdjęcia cyfrowe przy pomocy skaningowego mikroskopu elektronowego (SEM) typu XL (Phenom) przy przyspieszonym napięciu 5 kV. Wykonałem 215 zdjęć cyfrowych proszków z soku malinowego o rozdzielczości 1024x1024 120dpi, 24-bitowej głębi kolorów oraz dokładności wyświetlania 120 dpi zapisanych w formacie nieskompresowanym „TIFF”. Te działania również wykonałem w ramach współpracy z zespołem w SGGW w Warszawie.

W kolejnym etapie badań wykonałem przetwarzanie obrazu. W pierwszym wariancie dla 215 zdjęć mikroskopowych przeprowadziłem przekształcenie punktowe obrazów. Celem operacji na zdjęciach mikroskopowych jest uwidocznienie informacji strukturalnych proszków z soku malinowego zawartych na bitmapie. Ponownie wykorzystałem oprogramowanie „PIDsystem” [Przybył K., Ryniecki A. i wsp. 2016] do obrócenia o 90° 215 zdjęć cyfrowych. W efekcie pozyskałem 430 zdjęć mikroskopowych (po 230 zdjęć mikroskopowych dla 0° i 90°). W kolejnym kroku przeprowadziłem analizę tekstury z wykorzystaniem macierzy współwystępowania pasm szarości (GLCM) [Przybył, K.; Gawalek, J. i wsp. 2018, Clausi D.A. 2022], która w grafice trójwymiarowej pozwoli przedstawić szczegóły o powierzchni za pomocą funkcji matematycznych (tekstur proceduralnych) [Gierz Ł., Przybył K. i wsp. 2021]. W tym celu wykonałem za pomocą „PIDsystem” przetwarzanie zdjęć cyfrowych z 24 do 8-bitowej głębi obrazu. W efekcie pozyskałem zdjęcia cyfrowe o rozdzielczości 1024x1024 oraz 256 odcieniach szarości w formacie „TIFF”. Przygotowana baza zdjęć monochromatycznych (8-bitowych) została zaimportowana do darmowego narzędzia ImageJ, za pomocą którego odpowiednio wyekstrahowałem deskryptory tekstury: Angular Second Moment (ASM), Entropy, Correlation, Contrast i Inverse Different Moment (IDM) [Haralick R.M. 1973, 1979, Przybył K. Boniecki P. i wsp. 2019, Gierz Ł., Przybył K. i wsp. 2021]. W efekcie pozyskałem zbiór składający się danych teksturalnych (przypadków uczących) dla poszczególnych rodzajów proszków z soku malinowego (430 przypadków uczących).

W drugim wariancie badawczym z 215 zdjęć mikroskopowych przy użyciu oprogramowania „PIDsystem” wykonałem również segmentację obrazów. Z każdego zdjęcia cyfrowego o rozdzielczości 1024x1024 wyodrębniłem 16 bitmap o wymiarach 256x256. Zapisywałem je jako nowy obraz w formacie „TIFF” tworząc pojedynczy przypadek uczący.

Operację tę powtarzano, w wyniku czego otrzymałem łączną ilość 3440 przypadków. W kolejnym kroku wykonałem zmniejszenie liczności bitmap tak, żeby każda z klas badawczych miała równą liczbę przypadków. W efekcie zbiór uczący dla CNN zawierał 1023 bitmap (przypadków uczących).

W kolejnym etapie badań przeprowadziłem proces głębokiego i maszynowego uczenia sieci. W tym celu zaprojektowałem dla pierwszego wariantu badawczego sieć neuronową typu MLP, dla której zbiór uczący reprezentował 5 danych wejściowych związanych z teksturą obrazu oraz 1 daną wyjściową określającą klasę proszków z soku malinowego. Wspomniany pierwszy wariant badawczy zawierał 430 zdjęć mikroskopowych określając przypadki uczące. Struktura opracowanej sieci MLP obejmowała: warstwę wejściową (InputLayer) tj. dane numeryczne w postaci 5 deskryptorów tekstury; warstwy ukryte, dla których ustawiono zakres od 10 do 25 warstw; 9 neuronów wyjściowych w warstwie wyjściowej obejmującej 9 klas prób badawczych proszków z owoców z funkcją aktywacji Tanh.

W ramach porównania skuteczności rozpoznawania ilości i rodzaju nośnika drugi wariant badawczy wymagał przygotowania konwolucyjnych sieci neuronowych. Zbiór uczący składał się z 1053 przypadków uczących (każdy jako bitmapa o wymiarach 256x256x1). Wykorzystałem CNN opartą o architekturę sieci MobileNet [**Howard A.G. i wsp. 2017**]. Struktura MobileNet wyjaśnia warstwa konwolucyjna, która polega na zastosowaniu dwóch podwarstw: depthwise convolution i pointwise convolution. Konwolucja głębinowa (ang. depthwise convolution) wykonuje operację konwolucji za pomocą jednego filtru konwolucyjnego na każdy kanał (neuron) w warstwie wejściowej, natomiast konwolucja punktowa (ang. pointwise convolution) tworzy liniową kombinację kanałów (neuronów) warstwy wyjściowej. MobileNet używa nieliniowości zarówno przy batch normalization jak i dla ReLu [**Le N.Q.K i wsp. 2019**]. Struktura opracowanej CNN obejmowała: warstwę wejściową (InputLayer) tj. bitmapę o wymiarach 256x256x1 o wartościach przeskalowanych liniowo do przedziału od 0 do 1 (z dyskretnymi wartościami pośród których każde dwa sąsiadujące elementy leżą na skali w odległości 1/256). Początkowy tensor został przekazany do pierwszej ukrytej warstwy, którą była standardowa warstwa konwolucyjna (Conv2D), z 32 filtrami dla każdego załadowanego obrazu. Następnie zastosowano 13 warstw konwolucji głębinowo-separacyjnej (Depthwise Separable Convolution), gdzie głębokość tensorów (liczba filtrów) wynosiła odpowiednio 32, 64, 128, 256 lub 1024 w zależności od numeru warstwy. Każda warstwa konwolucyjna tego typu składała się z podwarstw w podanej kolejności: normalizującej (BatchNormalization), która ma na celu przyspieszyć i zwiększyć stabilności sztucznych sieci neuronowych poprzez normalizację wejść warstw poprzez ponowne

wyśrodkowanie i ponowne skalowanie [Ioffe S. i wsp. 2015], aktywacyjnej (funkcja aktywacji ReLu) [Chollet F. 2019, 2021], depthwise convolution 2D, pointwise convolution 2D, normalizującej (BatchNormalization). Operację próbkowania global_average_pooling2d (w odróżnieniu od max_pooling stosowanej w standardowych warstwach konwolucyjnych). Podczas stosowania globalnego łączenia średnich, rozmiar puli jest nadal ustawiony na rozmiar danych wejściowych warstwy, ale zamiast maksymalnej, brana jest średnia z puli. Celem przedsięwzięcia podczas budowy modelu było zredukowanie ilości danych przekazywanych do warstw w pełni połączonych w klasyfikatorze.

Operacja dropout (parametr dropout ustawiono na 0,001) polegała na losowym wybieraniu określonej ilości cech wejściowych warstwy oraz zastępowaniu ich zerami [Li X. i wsp. 2021]. Warstwa wyjściowa składała się z 9 neuronów z funkcją aktywacji „softmax”. Zastosowana funkcja aktywacji to funkcja matematyczna, za pomocą której przekształcany jest wektor liczb w wektor prawdopodobieństw. W efekcie prawdopodobieństwa każdej wartości są proporcjonalne do względnej skali każdej wartości w wektorze. Pomiędzy wartościami konwolucyjnymi wystąpiła operacja ZeroPadding2D, która polega na poszerzeniu każdej z dwuwymiarowych charakterystyk map o jeden wiersz i jedną kolumnę. Następnie wykonywana była operacja DepthWiseConv2D, w wyniku której usuwane były wcześniej dodane kwadraty.

W kolejnym etapie badania wykonałem z zespołem analizę FTIR przy użyciu spektrofotometru firmy Perkin Elmer (Waltham, MA, USA) wyposażonego w urządzenie ATR z diamentem jako wewnętrznym elementem odbijającym. Widma próbek badawczych rejestrowano w funkcji absorbancji w zakresie liczby falowej $3550\text{--}350\text{ cm}^{-1}$ z rozdzielczością $0,9\text{ cm}^{-1}$.

W wyniku badań określiłem odpowiednie sieci neuronowe. Przed procesem uczenia sieci ustaliłem minimalną oraz maksymalną liczbę warstw ukrytych. Dla minimalnej liczby warstw ukrytych modelu neuronowego ustalono 10 warstw ukrytych, a maksymalna liczba warstw ukrytych zawierała 25 warstw. Zauważyłem, że dla zbioru uczącego wykorzystanego w badaniach przy niskiej liczbie warstw ukrytych, sieci neuronowe osiągały niską skuteczność klasyfikacyjną. W przypadku przekroczenia 25 warstw ukrytych sieci miały skłonność do przeuczenia. Spośród sieci, które osiągnęły wysoką skuteczność klasyfikacyjną a przy tym niski RMSE znalazły się te, które zawierały neurony w warstwie ukrytej z funkcją aktywacji: logistyczną, tanh, wykładniczą lub sigmoidalną. Proces uczenia sieci przy użyciu neuronów warstwy ukrytej z liniową funkcją aktywacji osiągały największy RMSE. Wykonałem symulację sieci, z których wybrałem i zachowałem adekwatny model neuronowy. Wybrany model neuronowy, czyli taki który ma największe zdolności klasyfikacyjne został utworzony z

5 neuronów w warstwie wejściowej, 24 neuronów w warstwie ukrytej i 9 neuronów w warstwie wyjściowej (Rysunek 1, I.2.2). Sieć typu MLP pozyskano z funkcją aktywacji Logistyczna (dla warstw ukrytych) oraz Softmax (dla warstwy wyjściowej). Efektywność MLPN 5:5-24-9:1 ze względu na poprawność klasyfikacji osiągnięto na poziomie 0,962, wartość RMSE była na poziomie: 0,029 dla zbiorów uczącego, testowego i walidacyjnego (Tabela 2, I.2.2). W ramach poprzednich badań przy użyciu aparatu cyfrowego oraz mikroskopu skaningowego określono strukturę mikrocząstek w proszkach z soku truskawkowego na podstawie parametrów takich jak: barwa RGB, kształt oraz tekstura [Przybył K. i wsp. 2018, Przybył K., Boniecki P. i wsp. 2019]. Zaobserwowałem, że wysoka skuteczność klasyfikacji na poziomie 0,99 oraz RMSE na poziomie: 0,03 otrzymała sieć typu MLP 30:30-19-4:1 z wykorzystaniem parametrów powiązanych ze sobą takich jak: barwa RGB oraz wybrane parametry tekstury z liczbą 1960 przypadków uczących. W obecnych badań spróbowałem ocenić teksturę obrazu przy użyciu tym razem struktury mikrocząstek ze zdjęcia mikroskopowego. Zaobserwowałem w odniesieniu do obecnych badań, że otrzymana sieć typu MLP 5:5-24-9:1 (Rysunek 1, I.2.2), dla których wyznaczono 5 deskryptorów tekstury wypadła znacznie lepiej przy klasyfikowaniu próbek proszków z owoców o niższej liczbie przypadków uczących (430 przypadków uczących). W przypadku wykorzystania współczynników kształtu w poprzednich badaniach ta skuteczność klasyfikacji była nieco niższa i osiągnęła dla sieci MLP 9:9-9-4:1 wartość na poziomie 0,94, RMSE wynosiła: 0,13 (144 przypadki uczące) [Przybył K. i wsp. 2018] (Załącznik 4: **poz. II.4.47**). W ostatnich badaniach na proszkach z soku malinowego wykazałem, że powodem mniejszej skuteczności rozpoznawania mikrocząstek za pomocą kształtu jest liczba ich przypadków uczących. W sieci MLP 8:8-44-9:1, dla której wyznaczono 2903 przypadki w postaci mikrocząstek proszku z soku malinowego uzyskałem najmniejszy błąd RMSE na poziomie: 0,01. Wraz ze wzrostem liczby przypadków w postaci mikrocząstek zwiększała się w sieci MLP ich skuteczność rozpoznawania [Przybył K., Samborska K. i wsp. 2021] (I.2.1). W obecnych badaniach przy procesie maszynowego uczenia sieci zastosowałem algorytm Broyden–Fletcher–Goldfarb–Shanno (BFGS), który informuje o krzywiźnie funkcji wydajności oraz pozwala określić kierunek wyszukiwania minimalnego punktu docelowego przy wydajności w ramach sieci. Ten algorytm w odniesieniu do pozostałych metod staje się być dokładniejszy i wydajniejszy na zbiorze testowym. Wynika to z faktu uwzględnienia mniejszej liczby iteracji w procesie uczenia sieci [Zhao W. 2021]. Dotyczy to porównania skuteczności pomiędzy wcześniejszymi badaniami, dla których algorytmami wykorzystywanymi były funkcje uczenia się z wykorzystaniem algorytmu propagacji wstecznej (ang. Back Propagation, BP) oraz gradientu sprzężonego (ang. Conjugate Gradient,

CG). Dla porównania algorytmy BP oraz CG wykazały, że wraz ze wzrostem liczby iteracji na zbiorze testowym zwiększa się skuteczność identyfikowania proszków pozyskanych z soku aroniowego [Przybył K. i wsp. 2019] (Załącznik 4: **poz. II.4.46**) czy truskawki [Przybył K. i wsp. 2018]. W ostatnich badaniach, dla których materiałem badawczym były proszki z soku malinowego poziom iteracji był także wyższy [Przybył K., Samborska K. i wsp. 2021] (**I.2.1**) niż przy zastosowaniu obecnej metody uczenia, dla której wartość iteracji wynosiła 65.

W ramach porównania wyników badań i sposobu rozpoznawania proszków spożywczych w tym proszków z soku malinowego wykorzystałem technikę głębokiego uczenia. W odróżnieniu do wcześniej stosowanych rozwiązań z wykorzystaniem uczenia maszynowego efektywniejszym typem sieci okazała się MLPN od sieci o radialnych funkcji bazowych (RBFN) [Przybył K. i wsp. 2018]. Porównując MLPN do CNN należałoby zrozumieć różnice pomiędzy uczeniem maszynowym a uczeniem głębokim. Model uczenia maszynowego polega na mapowaniu zmiennych wejściowych (obraz, sygnał akustyczny lub dane numeryczne) warstwy wejściowej w zmienne wyjściowe warstwy wyjściowej. W przypadku głębokiego uczenia sieci neuronowe przeprowadzają operację mapowania za pomocą transformacji danych z warstwy wejściowej do kolejnych podwarstw, aż do warstwy wyjściowej. W CNN konwolucja wykorzystuje funkcję jądra i wiąże się ze zwiększeniem rzędowości kopii tensora, na którego podstawie wykonywane są operacje, jednak nie musi wiązać się ze zwiększeniem jej wymiarowości [Nelli F. 2018]. Przykładem zastosowania sieci konwolucyjnych jest algorytm klasyfikacji obrazów ze względu na występowanie powtarzających się, dających się rozpoznać i podobnych do siebie kształtów w obrazie. W takim przypadku kształt tensora wejściowego sieci można opisać kształtem (próbki, wysokość obrazu, szerokość obrazu, głębina jako ilość wymiarów przestrzeni kolorów RGB) [Nelli F. 2018].

W wyniku tych badań przeprowadziłem analizę zmian w strukturze chemicznej próbek koncentratu z malin z dodatkiem różnych nośników wykonując widma w podczerwieni (Rysunek 2, **I.2.2**).

Analizując pierwszy obszar w zakresie liczb falowych od 2500 do 3550 cm^{-1} , który pokazuje szerokie wiązanie asymetryczne spowodowane walencyjnymi wibracjami grup hydroksylowych wiązań rozciągających OH zaangażowanych w wiązania wodorowe oraz drań rozciągających C-H. W tym rejonie pojawia się ostre pasmo przy liczbie falowej 2950 cm^{-1} , które przypisuje się drganiom walencyjnym asymetrycznego rozciągania C-H w grupie CH_2 [Wongphan P. i wsp. 2020]. Największą intensywność tego pasma obserwujemy dla próby o

zawartości 60% maliny i 40% nośnika maltodekstryny oraz 50% maliny i 50% nośnika – gumy arabskiej.

Kolejny obszar widmowy pomiędzy 1500 a 900 cm^{-1} reprezentują silne wiązania rozciągające C-O, C-C oraz C-O-H i C-O-C, różnych oligo- i polisacharydów [Naumann D. 1998]. W tym rejonie można zauważyć, że największa intensywność absorpcji przypisana jest w paśmie przy 1085 cm^{-1} . Intensywność w tym obszarze przypisana jest drganiom rozciągającym C-O, które wykazują największą intensywność absorpcji w próbkach z dodatkiem maltodekstryny. Ostatni obszar „fingerprint” przypadający poniżej 900 cm^{-1} odpowiada za regiony krystaliczne i wskazuje na zmiany konformacyjne w badanym materiale [Ramirez-Hernandez A. i wsp. 2019]. Dla przeanalizowanych próbek przypada on dla liczby falowej 700 cm^{-1} , a intensywność pasma absorpcji uzależniona jest od proporcji składników danej próbki [Melanie H. i wsp. 2015]. W obszarze tym obserwujemy delikatne przesunięcie się maksimum absorpcji w stronę krótszych liczb falowych dla próbek z większą zawartością malin 60 i 70% oraz z dodatkiem maltodekstryny jako nośnika odpowiednio 40 i 30%.

W kolejnym etapie wykonałem analizę wariancji (ANOVA), która pozwoliła porównać 9 klas badawczych na podstawie deskryptorów tekstury (pośrednio wyznaczone ze zdjęć mikroskopowych) oraz obszaru widmowego (pozyskanego przy użyciu spektrofotometrii w podczerwieni). W Tabeli 4 (I.2.2) przedstawiono wyniki 9 klas badawczych różniących się od siebie stopniem scukrzenia oraz polisacharydem.

Omawiając zmienną entropii [Gierz Ł., Przybył K. i wsp. 2021] (Załącznik 4: poz. II.4.36), która w literaturze określa ilość energii traconą w wyniku reakcji fizycznej [Hall-Beyer M. 2017] można zaobserwować podobieństwo pomiędzy klasami badawczymi. Okazuje się, że największe podobieństwo dla zmiennej entropii występowało pomiędzy klasami badawczymi z udziałem 30% ilości cukru pomiędzy IN i MD. Statystycznie porównując grupy badawcze na podstawie deskryptora entropii zaobserwowano podobieństwo w grupie proszków z soku malinowego z udziałem IN (IN50, IN60, IN70). Oprócz tego zmienna entropii wykazała podobieństwo w grupach m.in. dla GA60 i GA70 oraz MD50 i MD60. W przypadku zmiennych contrast i correlation analiza wariancji wykazała, że poszczególne grupy różnią się od siebie. Zaobserwowano, że zmienna ASM, która obliczana jest jako drugi moment kątowy (miara przyspieszenia obrotowego) wykazała homogeniczność wariancji (wszystkie wariancje są praktycznie sobie równe). W przypadku zmiennej IDM zaobserwowano, że najbardziej znaczącą grupą badawczą są proszki z soku malinowego z 50% udziałem cukru w postaci gumy arabskiej. Statystycznie podobieństwo pomiędzy grupami zaobserwowano dla proszków z soku malinowego z udziałem cukru gumy arabskiej (GA50, GA60, GA70).

Dla porównania z deskryptorami tekstury wykonano analizę dla absorbancji (FTIR). Stwierdzono podobnie jak dla deskryptora IDM, że w obszarze widmowym (na podstawie FTIR) dla klas badawczych koncentratu z malin z dodatkiem różnych nośników największe podobieństwo występuje z udziałem gumy arabskiej i maltodekstryny (Tabela 4, **I.2.2**).

W ramach porównania grup hydroksylowych wiązań rozciągających OH zaangażowanych w wiązania wodorowe oraz drgań rozciągających C-H, dla których zaobserwowano na rysunku największą intensywność pasma z udziałem klasy badawczej GA50 można statystycznie potwierdzić, że w odniesieniu do wyników badań jest znaczącą grupą (Tabela 4, **I.2.2**). W ostatnio przeprowadzonych badaniach zauważono, że największe różnice występują także przy wilgotności i aktywności wody właśnie dla klasy badawczej GA50 [**Przybył K., Samborska K i wsp. 2021**] (**I.2.1**).

W przypadku kolejnego obszaru, który dotyczy różnych związków oligo- i polisacharydów zauważono, że największa intensywność występuje z udziałem maltodekstryny. W analizie wariancji wykazano, że zmienne takie jak entropia, correlation i contrast statystycznie określają, że znaczącymi grupami są proszki z soku malinowego z różnym udziałem cukru maltodekstryny.

Pozyskane ze zbioru uczącego (deskryptory tekstury). Na rysunku 3 i tabeli 5 (**I.2.2**) zaobserwowano, że zmienna Entropii silnie ujemnie korelowała ($R^2=-0,89$) ze zmienną IDM. Analiza PCA wykazała, że najmniejsza korelacja pomiędzy deskryptorami tekstury wystąpiła przy zmiennej ASM.

W przyszłości badania będą koncentrować się na wykorzystaniu sztucznych sieci neuronowych oraz analizy obrazu do kontroli tworzenia mikrocząstek proszków z owoców w trybie on-line. Niemniej nadal brakuje wiedzy na temat podstaw procesu tworzenia mikrocząstek. W literaturze można znaleźć bardzo dużo informacji na temat budowy i morfologii mikrocząstek [**Boel E. i wsp. 2020**]. Niestety nie ma określonej metody wspomagającej projektowanie określonego typu morfologii mikrocząstek. W tym celu autorzy dążą do uzyskania optymalnego rozwiązania, który pozwoli morfologię cząstek monitorować.

Podsumowując, monitorowanie jakości oraz parametrów suszenia proszków spożywczych (w tym stopnia scukrzenia oraz rodzaju polisacharydu) na podstawie nowoczesnych technik takich jak: komputerowa analiza obrazu i modelowanie neuronowe mogą przyczynić się do znacznego rozwoju cywilizacyjnego. Zwiększenie powtarzalności uzyskiwanych proszków przy jednoczesnym zmniejszeniu kosztów oceny jakościowej i w konsekwencji ceny naturalnych proszków spożywczych, przełoży się na zwiększenie ich popularności wśród producentów żywności, a to z kolei przełoży się na zwiększenie

konsumpcji produktów naturalnych wśród społeczeństwa eliminując w znacznym stopniu dodatki syntetyczne.

Ad. 4.4.3. Fruit powders analysis using machine learning based on color and FTIR-ATR spectroscopy. Case study: black currant powders – publikacja 3 (I.2.3).

W ostatnich latach wzrosła produkcja owoców, jest to konsekwencja ich wysokich walorów smakowych oraz znaczącego udziału w diecie człowieka [**Wallace T.C., Bailey R.L. i wsp. 2020**]. Owoce są bogate w składniki odżywcze, które dostarczają niezbędnych substancji do prawidłowego funkcjonowania organizmu tj.: białko, węglowodany, witaminy, składniki mineralne, błonnik, antyoksydanty czy woda. Owoce są produktami, które dostarczają organizmowi potrzebnych składników odżywczych i odgrywają ważną rolę w profilaktyce wielu chorób. Wobec powyższego kluczowe wydaje się być działanie na rzecz ich konserwacji. W badaniach skupiłem się na jagodach czarnej porzeczki (*Ribes nigrum L.*).

W ramach projektu podjąłem kolejną próbę porównania wpływu wybranych parametrów jakościowych proszków z soku porzeczkowego na podstawie FTIR oraz uczenia maszynowego. Celem utylitarnym jest zastosowanie nieinwazyjnej metody sztucznej inteligencji do opracowania docelowo inteligentnego systemu oceny jakości wybranych produktów spożywczych dla potrzeb pracy w systemach on-line. Prace pozwolą wspomagać rozpoznawanie deskryptorów barwy uwzględniając ilość i rodzaj nośnika w proszkach z soku porzeczkowego przy użyciu metod FTIR oraz uczenia maszynowego.

W pracy przeprowadziłem charakterystykę właściwości proszków z soku porzeczkowego, która pozwoliła mi ocenić jakość otrzymanych proszków spożywczych. Wykonałem pomiar aktywności wody przy użyciu analizatora dyfuzji i aktywności wody ADA-7 (COBRABID, Poznań) z systemem automatycznej rejestracji czasu przebiegu ewakuacji wody dla poszczególnych próbek [**Baranowska H.M., Masewicz Ł. i wsp. 2018**]. Wykonane próby przeprowadziłem w 5 powtórzeniach (łącznie n=90). Aktywność wody wykonałem zgodnie z procedurą przy proszkach z soku malinowego według **Przybył K., Samborska K i wsp. 2021 (I.2.1)**. W kolejnym etapie wykonałem pomiar barwy proszków z soku porzeczkowego przy pomocy spektrofotometru SP-60 firmy X-Rite. Pomiar barwy zrobiłem w 30 powtórzeniach dla każdego wariantu proszku z soku porzeczkowego.

Identyfikację wiązań wodorowych w badanych próbkach, tj. próbkach proszku z soku porzeczkowego, przeprowadziłem z wykorzystaniem spektrofotometrii w podczerwieni. Badania przeprowadziłem przy użyciu spektrofotometru wyposażonego w przystawkę ATR zawierającą urządzenie diamentowe jako element wewnętrznego odbicia firmy PerkinElmer

Ltd. (Waltham, MA, USA). Widma badanych próbek o masie $0,005 \pm 0,005$ g zostały zarejestrowane w funkcji absorpcji w zakresie liczby falowej $4000-500\text{ cm}^{-1}$, z rozdzielczością $0,9\text{ cm}^{-1}$. Każde widmo jest wynikiem nałożenia pięciu powtórzeń. Badania przeprowadzone dla proszków z owoców czarnej porzeczki zostały przeprowadzone analogicznie do proszków z soku malinowego zgodnie z procedurą opisaną w **Przybył K., Samborska K i wsp. 2021 (I.2.1)**.

W badanych próbach przy użyciu parametrów barwy, przygotowałem 30 zbiorów uczących, które reprezentowały najmniejszy i największy udział nośnika w roztworze (30% i 50% jego zawartości). Celem tego etapu badań było zastosowanie uczenia maszynowego do opracowania adekwatnej topologii sieci neuronowej, którą okazała się być sieć typu MLP [**Przybył K. i Koszela K. 2023**] (Załącznik 4: **poz. II.4.26**). Struktura każdej z tych sieci charakteryzowała się 3 neuronami w warstwie wejściowej, od 3 do 10 neuronów w warstwie ukrytej oraz 2 neuronami w warstwie wyjściowej. W ramach uczenia maszynowego użyto algorytmu BFGS. W tym etapie badań uzyskałem optymalne sieci MLP, które były w stanie efektywnie identyfikować określone rodzaje proszków z soku porzeczkowego za pomocą barwy $L^*a^*b^*$.

W wyniku badań pomiaru wilgotności prób proszków z soku porzeczkowego zaobserwowałem, że, różniły się od siebie ilością i typem nośnika. Celem analizy było porównanie nośników pomiędzy próbami użytymi w działaniu badawczym. W odniesieniu do poprzednich badań związanych z proszkami z soku malinowego [**Przybył K., Samborska K i wsp. 2021, Przybył K., Koszela K. i wsp. 2021**] (I.2.1, I.2.2), potwierdziłem, że nośniki z mniejszym udziałem w roztworze owocowym prowadzą do uzyskania najniższej wilgotności w proszkach z owoców. Zaobserwowałem, że proszki z soku malinowego wzbogacone dodatkiem inuliny osiągnęły w obecnych badaniach proszków z soku porzeczkowego równie niski poziom wilgotności. W efekcie proszki z soków porzeczkowego jak i malinowego [**Przybył K., Koszela K. i wsp. 2021**] (I.2.2) wzbogacone dodatkiem inuliny charakteryzują się jedną z najniższych zawartości wody w porównaniu do pozostałych próbek proszków z soku porzeczkowego zawierających inne nośniki. W obecnych badaniach zauważyłem także, że celuloza mikrokryształiczna oraz błonnik osiągnęły niską zawartość wilgotności w próbach. Z perspektywy przechowywania tych produktów przez dłuższy okres przydatności projektowanie proszków owocowych z nośnikiem inuliny dla porzeczki jak i maliny wydaje się być korzystniejszym przedsięwzięciem. Obecne badania potwierdzają jednoznacznie, że proszki z soku porzeczkowego z dodatkiem gumy arabskiej (GA) osiągają najwyższy poziom wilgotności w próbach, niezależnie od zawartości nośnika w roztworze owocowym. W ramach

utrwalania żywności i sposobu przechowywania przez dłuższy okres czasu suszenie proszków owocowych z udziałem gumy arabskiej wydaje się być jednak mniej skutecznym działaniem [Ray A.K. i wsp. 1995, Fernandes R.V.D.B. i wsp. 2014, Przybył K., Masewicz Ł. i wsp. 2021]. Przyczynę wysokiej wilgotności dla gumy arabskiej określano na podstawie jej właściwości.

W ramach działań badawczych sprawdziłem aktywność wody dla proszków z soku porzeczkowego. To istotny parametr, który istotnie wpływa na stabilność mikrobiologiczną i bezpieczeństwo podczas dłuższego przechowywania produktów spożywczych. Im wyższy poziom aktywności wody tym zwiększa się rozwój mikroorganizmów w produkcie spożywczym. W wyniku niskotemperaturowego suszenia rozpyłowego osiągnięto najniższą aktywność wody w próbach proszków z soku porzeczkowego [Samborska K., Jedlińska A. i wsp. 2019, Jedlińska A., Samborska K. i wsp. 2019]. Na podstawie przeprowadzonych wcześniej przeze mnie badań z udziałem inuliny wykazałem w proszkach z soku malinowego najniższą aktywność wody. W obecnych badaniach z udziałem proszków z soku porzeczkowego również pozyskano niski poziom aktywności wody dla inuliny, białek serwatkowych mleka, celulozy mikrokrystalicznej oraz błonnika (Rysunek 3, I.2.3). Tym samym w celu przedłużenia okresu przydatności do spożycia i utrzymania wysokiej jakości produktów oprócz inuliny alternatywnymi nośnikami wydają się być białka serwatkowe mleka, celuloza mikrokrystaliczna i błonnik. W aspekcie kryterium wartości aktywności wody poruszonym dla proszków z soku malinowego, gdzie zastosowano niskotemperaturowe suszenie rozpyłowe w obecnych badaniach również je utrzymano. Praktycznie wszystkie proszki z soku porzeczkowego uzyskały niską aktywność wody, poniżej 0,2 z wyjątkiem maltodekstryny (0,25). To kryterium niskiej aktywności istotnie wpływa na jakość mikrobiologiczną i przedłużenie trwałości produktów spożywczych.

Przeprowadziłem analizę statystyczną metodą ANOVA uwzględniając test Tukey'a i wyniki odnoszą się do modelu przestrzeni barw $L^*a^*b^*$ proszków z soku porzeczkowego. Model przestrzeni barw $L^*a^*b^*$ pozwala określić trzy podstawowe składowe barw takie jak: jasność (L^*), kolor czerwony-zielony (a^*) oraz żółty-niebieski (b^*). W kontekście testu Tukey'a otrzymałem podklasy dla proszków spożywczych z 30% i 50% udziałem nośnika. Oznacza to, że pewne próby proszków są podobne do siebie, a inne różnią się. Zaobserwowałem, że składowa barwy odpowiadająca za jasność (L^*) wykazała, że proszek z soku porzeczkowego z 50% udziałem białek serwatkowych mleka (W50) statystycznie znajduje podobieństwo z inuliną (IN50) oraz błonnikiem (F50). W przypadku składowej (a^*) proszki z soku porzeczkowego z 50% udziałem nośnika wykazują statystycznie największe

podobieństwo między sobą m.in. białka serwatkowe mleka, inulina, celuloza mikrokrystaliczna oraz błonnik. Stwierdziłem, że w przypadku składowej (b^*) proszki spożywcze z 50% udziałem białek serwatkowych mleka (W50) wykazują istotnie statystycznie podobieństwo z maltodekstryną (MD50). Przedstawiłem analizę wariancji dla różnych prób z najmniejszym udziałem nośnika w roztworze porzeczkowym. Okazuje się, że składowa L^* istotnie statystycznie wykazuje różnice pomiędzy próbkami proszków z soku porzeczkowego. W przypadku składowej (a^*) i (b^*) zaobserwowałem w proszkach z soku porzeczkowego z 30% udziałem nośnika istotnie statystycznie podobieństwo pomiędzy błonnikiem (F70) a celulozą mikrokrystaliczną (C70). Porównując, wspomniane wyżej, wyniki związane z wilgotnością i aktywnością wody pozwoliłem zidentyfikować jak istotnie statystycznie wpływa udział nośnika tj. inuliny. W przypadku barwy przy próbach proszków z soku porzeczkowego ze względu na składowe modelu przestrzeni barw $L^*a^*b^*$ inulina staje się jednym z tych nośników, który istotnie statystycznie wyznacza podobieństwo.

Dla porównania przedstawiłem przebieg widma w podczerwieni dla 12 prób proszku z owoców czarnej porzeczki z różną zawartością nośników. Szerokie pasmo absorpcji przy 3290 cm^{-1} oraz węższe pasmo przy liczbie falowej 2900 cm^{-1} są spowodowane drganiami rozciągającymi grup OH tworzących wiązania wodorowe oraz asymetrycznym rozciąganiem grup CH_2 [Wongphan P. i wsp. 2020, Yu M i wsp. 2019]. Największą intensywność tych pasm zaobserwowałem dla próby F70, która zawiera najmniejszą ilość błonnika. Natomiast najmniejszą intensywność absorpcji w tym obszarze widmowym wykazuje próbka MD70 o najmniejszej zawartości maltodekstryny. Kolejne pasmo absorpcji w całym obszarze widmowym przypada na 1732 i 1621 cm^{-1} , które przypisano absorpcji grup karbonylowych estrów (COOR) i pasmu rozciągania jonów karboksylanowych (COO) [Aly A. i wsp. 2019]. Literatura podaje, iż liczbie falowej 1708 cm^{-1} przypisuje się wiązania odpowiadające za lipidy a w przedziale $1705\text{-}1575\text{ cm}^{-1}$ amid I. Ze wszystkich przebadanych próbek najwyższą intensywność pasm absorpcji w tych obszarach obserwuje się dla próbki GA50, czyli o zawartości 50% gumy arabskiej. Wszystkie widma pokazały typowe pasmo drgań rozciągających C-O-C przypisane carbohydrate region ($1200\text{-}900\text{ cm}^{-1}$) [Ying D. i wsp. 2017]. Maksimum absorpcji w tym obszarze przypada również próbce o zawartości 50% gumy arabskiej (GA50) natomiast niższa zawartość tego nośnika (GA70) powoduje spadek intensywności absorpcji. Odpowiadający za regiony krystaliczne obszar fingerprint występujący poniżej 900 cm^{-1} , który wskazuje zmiany konformacyjne zachodzące w badanym materiale [Melanie H. i wsp. 2015] obserwuje się dla liczby falowej 764 cm^{-1} , niezależnie od rodzaju i ilości dodanego nośnika.

W wyniku przeprowadzonego procesu uczenia maszynowego otrzymałem 30 MLPN, które charakteryzowały się wysokim wskaźnikiem determinacji dla zbioru testowego na poziomie 0,99. MLPN wygenerowane dla zbioru uczącego wykazały równie wysoki poziom skuteczności rozpoznawania prób proszków z owoców czarnej porzeczki. Zgodnie z przyjętą zasadą w uczeniu maszynowym otrzymane modele spełniają kryterium dobrego dopasowania się do sieci (reguła overfitting by under fitting) [Bashir D. i wsp. 2020]. W strukturze MLPN warto zauważyć, że zakres liczby neuronów w warstwie ukrytej miał wpływ na znalezienie optymalnej sieci MLP. W przypadku funkcji aktywacji dla neuronów w warstwie ukrytej, najsprawniejsze okazały się funkcje tanh oraz wykładnicza dając najlepsze rezultaty w wyniku uczenia tych sieci. Tanh i Exponential wydają się być bardziej elastycznymi funkcjami aktywacji niż pozostałe, co przekłada się na uzyskanie lepszego wskaźnika determinacji modelu na zbiorze testowym [Przybył K., Masewicz Ł i wsp. 2021, Dubey S.R., Singh P. i wsp. 2022]. W praktyce opierając się na zasadach uczenia maszynowego wybór funkcji aktywacji zależy od stawianego problemu decyzyjnego jak i topologii sieci. Nieliniowość tych funkcji aktywacji także może wpływać na skuteczniejszą wydajność rozpoznawania tych danych.

W ramach przeprowadzonych eksperymentów uczenia maszynowego zaobserwowałem również niewiele wyższą skuteczność identyfikacji proszków z soku porzeczkowego, gdy ilość nośnika w roztworze wynosiła 50% niż w przypadku prób z 30% udziałem tego nośnika. W przypadku rodzaju nośnika proces identyfikowania poszczególnych prób najskuteczniej odbywał się przy doborze białek serwatkowych mleka (W70), gumy arabskiej (GA70), maltodekstryny (MD70), inuliny (IN70) oraz celulozy mikrokrystalicznej (C70) biorąc pod uwagę wartość najmniejszego błędu popełnionego na zbiorze testowym z jego 30% (Tabela 3, I.2.3) oraz 50% (Tabela 4, I.2.4) udziałem w roztworze. Gorsze rezultaty rozpoznawania prób proszków z soku porzeczkowego otrzymałem z udziałem błonnika. Najmniejszy błąd popełniony na zbiorze testowym wśród pozyskanych MLPN w procesie uczenia maszynowego dla 30% zawartości nośnika osiągnęła sieć MLP 3-6-1 (model C70zW70), dla której błąd osiągnął wartość na poziomie 0,0025. Dla porównania przy rozpoznawaniu nośnika z jego 50% udziałem w roztworze najmniejszy błąd na zbiorze testowym osiągnęły modele takie jak: MLP 3-8-1 (MD50zGA50), MLP 3-9-1 (IN50zGA50) oraz MLP 3-9-1 (W50zGA50), dla których błąd wynosił $0,000005 \pm 0,000001$. Zaobserwowałem, że MLPN z 50% udziałem gumy arabskiej (GA50) dobrze odwzorowano wyniki dla 3 modeli. To oznacza, że te MLPN w grupie z 50% zawartością nośnika skutecznie przewidują wyniki dla gumy arabskiej. W ramach porównania z danymi otrzymanymi metodą FTIR można stwierdzić, że wraz ze wzrostem

zawartości nośnika zwiększa się intensywność absorpcji oraz liczba poprawnych modeli MLPN, które dobrze generalizują zależność między danymi wejściowymi a wynikiem.

Przedstawione powyżej dane sugerują możliwość wykorzystania bezinwazyjnych metod wspomagających proces utrwalania żywności. Poznany mechanizm pozwala na utrzymanie autentyczności i homogeniczności otrzymanych w wyniku suszenia rozpyłowego proszków z soku porzeczkowego. Uczenie maszynowe wydaje się być zatem skutecznym narzędziem do kontroli autentyczności oraz jakości produktów spożywczych.

Ad. 4.4.4. Efficiency of identification of blackcurrant powders using classifier ensembles – publikacja 4 (I.2.4).

Wraz z rozwojem technologii zmienia się pogląd dotyczący jakości i bezpieczeństwa żywności. Procesy produkcji, zarządzania, dystrybucji i konsumpcji żywności znacząco ewoluowały na przestrzeni kilku ostatnich lat. Te działania wynikają ze znaczniejszego skupienia się na wzmacnianiu systemów kontroli jakości i bezpieczeństwa żywności [**Singh P. i wsp. 2022, Mavani N.R. 2022, Przybył K. i Koszela K. 2023**] (I.2.3). Patrząc jak w ostatnim czasie obserwuje się zmiany klimatyczne [**Thomas A. i wsp. 2021**], zachowania i preferencje konsumentów [**Xu Y. i wsp. 2023**] i problemy zafałszowań żywnościowych, wyzwaniem staje się być zapewnienie bezpieczeństwa żywnościowego na rzecz zdrowia człowieka [**Khan R. i wsp. 2021**]. Sukcesywne wprowadzanie nowocześniejszych rozwiązań w branży spożywczej mających na celu poprawę w lokalnych systemach kontroli jakości żywności wpływają na poprawę globalnego bezpieczeństwa żywności [**Tayi A. 2018, Vermesan O. 2022**]. Wskutek ciągłych postępów technologicznych szczególnie w dziedzinie sztucznej inteligencji, istnieje prawdopodobieństwo zintensyfikowania kontroli jakości żywności [**Vermesan O. 2022**]. Te zmiany zarówno w jakości, jak i bezpieczeństwie żywności, mogą stać się istotnym elementem osiągnięcia globalnego sukcesu gospodarczego.

Obecnie wydajna, skuteczna analiza i szybkość implementacji algorytmów są kluczowymi aspektami przy ocenie jakościowej produktów spożywczych. Poszukuje się nieinwazyjnych rozwiązań mających na celu osiągnąć wysoką dokładność klasyfikowania i estymowania różnych produktów spożywczych.

W pracy przedstawiłem różne struktury algorytmów uczenia maszynowego pozwalające ocenić efektywność identyfikowania proszków z soku porzeczkowego na podstawie informacji zakodowanej w zdjęciach mikroskopowych, pozyskanych w wyniku mikroskopii elektronowej (SEM). Rozpoznawanie proszków z owoców czarnej porzeczki wykonałem przy pomocy wyodrębniania cech tekstury z obrazu wspomaganego GLCM.

W wyniku badań opracowałem efektywny sposób rozpoznawania klas proszków z soku porzeczkowego przy pomocy zaawansowanych algorytmów uczenia maszynowego, który zaprezentowałem również na konferencji (Załącznik 4: **poz.II.7.2.7**). Biorąc pod uwagę autentyczność i utrzymanie jakości w wyniku pozyskiwania tych produktów spożywczych, proces identyfikowania różnych klas proszków spożywczych staje się również ważny ze względu na ich właściwości fizykochemiczne [Saifullah M. i wsp. 2016]. Próba zastosowania algorytmów uczenia maszynowego pozwoliła na skuteczne (autentyczne) rozpoznawanie właściwości pomiędzy różnymi rodzajami proszków porzeczkowych. Przetestowałem różne techniki uczenia maszynowego, otrzymując wydajne a zarazem optymalne porównania. Zaproponowałem rozwiązanie oparte przy pomocy metod zespołowych uczenia maszynowego w jeden metaklasyfikator [Yamaskin S. i wsp. 2022] do kontrolowania oceny jakościowej produktów spożywczych zwiększając skuteczność uogólniania modeli niż w przypadku każdego ze składowych algorytmów. Uczenie maszynowe może przyczynić się do usprawnienia standardów jakościowych, kontrolowania zafałszowań, jak i efektywności pozyskiwania produktów końcowych tj. proszków z soku porzeczkowego.

W pierwszym etapie pracy badawczej przygotowałem zbiór danych w oparciu o zdjęcia mikroskopowe (SEM) proszków z soku porzeczkowego. Procedurę przygotowania zdjęcia mikroskopowego opierałem o informacje sporządzone przy wykonywaniu zdjęć mikroskopowych z udziałem proszków z soku malinowego [Przybył K., Samborska K. i wsp. 2021] (I.2.1). Zdjęcia cyfrowe o rozdzielczości 2048x1576 w formacie „TIFF” mikrocząstek proszków z soku porzeczkowego otrzymano przy 500-krotnym powiększeniu w skali 100 µm (łącznie 630 zdjęć cyfrowych). Zbiór danych (zbiór uczący) zawierał 6 różnych klas proszków z owoców czarnej porzeczki. Każda klasa odpowiada za otrzymany proszek porzeczkowy w wyniku suszenia niskotemperaturowego z określonym nośnikiem, a nadto taka sama ilość zdjęć tj. po 105 obrazów mikroskopowych w katalogu.

W kolejnym etapie wykonałem wstępne przetwarzanie zbioru uczącego. Każde zdjęcie cyfrowe o rozdzielczości 2048x1576 z rozszerzeniem „TIFF” (zdjęcie pierwotne) przetworzono do 8-bit obrazu wtórnego o rozdzielczości 1400x1400 z rozszerzeniem „jpg”. Wsadową transformację obrazu wykonałem z pomocą opracowanego przeze mnie algorytmu i dołączonej darmowej biblioteki Python Imaging Library (PIL) w języku Python ver. 3.9. W kolejnym kroku opracowałem algorytm segmentacji obrazów, aby pozyskać rozdzielczość obrazu na poziomie 1400x1400. Wykonałem tzw. kadrowanie obrazu z określonym krokiem w stosunku do parametrów osi x i y, nie powodując przy tym zniekształcenia obrazu. Ostatni etap wymagał przekształcenia obrazów punktowo o 90, 180, 270 stopni. Te działania pozwoliły mi

pozyskać 105 zdjęć 8-bitowych o rozdzielczości na poziomie 1400x1400 z rozszerzeniem „.jpg” dla każdej klasy w zbiorze uczącym. Zbiór testowy zawierał 210 zdjęć (6 klas po 35 zdjęć cyfrowych proszków z soku porzeczkowego). W zbiorze testowym zgodnie z zasadą uczenia maszynowego nie zawarto tych zdjęć, które należały do zbioru uczącego. Procedura przetwarzania obrazu odbyła się podobnie jak w przypadku zbioru uczącego z wykluczeniem przekształcenia punktowego.

W kolejnym etapie opracowałem algorytm przejścia z obrazu do wektora danych. Celem działania było przygotowanie zdjęcia jako wektora danych do analizy obrazu przy pomocy cech reprezentatywnych. W tym kroku zastosowałem teksturę obrazu do rozpoznawania proszków z soku porzeczkowego poprzez wykorzystanie GLCM. Poszczególne wyróżniki GLCM są obliczane według następujących wzorów [Gierz Ł. i Przybył K. 2022, Przybył K., Boniecki P. i wsp. 2019, Haralick R.M. 1979]:

$$\text{Contrast: } \sum P_{i,j}(i-j)^2 \quad (1)$$

$$\text{Dissimilarity: } \sum P_{i,j}|i-j| \quad (2)$$

$$\text{Homogeneity: } \sum \frac{P_{i,j}}{1+(i-j)^2} \quad (3)$$

$$\text{Energy: } \sqrt{\sum P_{i,j}^2} \quad (4)$$

$$\text{Correlation: } \sum P_{i,j} \left[\frac{(i-\mu_i)(j-\mu_j)}{\sqrt{(\sigma_i^2)(\sigma_j^2)}} \right] \quad (5)$$

$$\text{Entropy: } \sum p_{i,j} \log_2 p_{i,j} \quad (6)$$

Zaprojektowałem 35 klasyfikatorów do identyfikacji proszków z soku porzeczkowego. W uczeniu maszynowym dostrajałem różne klasyfikatory ze względu na ich hiperparametry [Saum N. i wsp. 2022, Gul E i wsp. 2021, Probst P. i wsp. 2019] w celu znalezienia najskuteczniejszego modelu do rozpoznawania proszków z owoców. Jednym z 35 klasyfikatorów był metaklasyfikator, czyli połączenie 3 pojedynczych klasyfikatorów takich jak: LogisticRegression, Bagging i Random Forest. Metaklasyfikator dla porównania z pojedynczymi klasyfikatorami posłużył mi do poprawy dokładności sklasyfikowanych danych. W przypadku pojedynczych algorytmów uczenia maszynowego wykorzystałem Decision Trees (DF), Random Forest (RF), Adaptive Boosting (AdaBoost), Bootstrap Aggregating (Bagging), Stochastic Gradient Descent Classifier (SGDClassifier), RidgeClassifier, Perceptron, MultiLayer Perceptron (MLPPerceptron) oraz GaussianProcessClassifier.

Wyniki uczenia przedstawiłem przy pomocy wskaźników jakości tj. Precision, Recall, Accuracy oraz F-score uwzględniając kryterium parametrów tekstury obrazu przy użyciu GLCM. Badania dotyczące rozpoznawania różnych rodzajów proszków z soku porzeczkowego za pomocą różnych algorytmów klasyfikacyjnych wykazały, że najskuteczniejszym pojedynczym klasyfikatorem okazał się algorytm RandomForest. W kontekście zastosowanych nośników odróżniających proszki z soku porzeczkowego ten algorytm osiągnął najlepsze wyniki. Wskaźniki precyzji, recall jak i F-Score to kluczowe metryki wydajności pozyskiwanych klasyfikatorów. Okazało się, że również dla algorytmu RandomForest wszystkie te wskaźniki były najwyższe. To oznacza, że ten algorytm osiągnął najwyższą zdolność do dokładnego rozpoznawania proszków z soku porzeczkowego. Wysoki poziom precision wyjaśnia, że Random Forest ma niewielką liczbę fałszywie pozytywnych wyników, podczas gdy wysoki recall oznajmia dużą zdolność do wykrywania większości istniejących przypadków uczących. Warto zauważyć, że inne algorytmy również wykazywały dość wysoką skuteczność rozpoznawania proszków z owoców m.in. Bagging i Decision Tree.

W wyniku uczenia maszynowego dla porównania poszczególnych cech charakterystycznych tekstury obrazu przy użyciu GLCM przedstawiłem rezultat także Metaklasyfikatora, który równie skutecznie rozpoznawał proszki spożywcze. Metaklasyfikator osiągnął najwyższy wynik przy identyfikowaniu proszków z soku porzeczkowego, gdzie atrybutem obrazu były współczynniki entropii oraz homogeneity. W przypadku atrybutów contrast, coorelation i dissimilarity najskuteczniejszym pojedynczym klasyfikatorem został algorytm typu Random Forest. Ostatni atrybut w GLCM odpowiadający za wskaźnik energii wykazuje najwyższą skuteczność rozpoznawania przy pomocy modelu Bagging. Zaobserwowałem, że metaklasyfikator charakteryzuje się w większości najwyższym wskaźnikiem precision w odniesieniu do wszystkich pozostałych pojedynczych klasyfikatorów. Oznacza to, że dobrałem skuteczne metody na etapie preprocesingu danych dla proszków spożywczych. Dobrałem odpowiednie algorytmy uczenia maszynowego, aby otrzymać skuteczny metaklasyfikator oraz doprowadziłem do dobrego dostrajania hiperparametrów, otrzymując optymalne wskaźniki dokładności w wyniku procesu uczenia.

W literaturze i doświadczeniach badawczych można wykazać, że atrybuty oparte na bazie GLCM to efektywne narzędzie do analizy obrazów, w tym obrazów żywności. W ostatnich badaniach wykazałem, że atrybuty w tym Entropy są jednym z kluczowych cech identyfikujących ziarna zbóż podczas próby wysiewu z różną prędkością roboczą maszyny do siewu nasion [Gierz Ł. i Przybył K. 2022]. W innych badaniach nad proszkami z soku truskawkowego wykazałem również unikalność rozpoznawania atrybutów przy pomocy

GLCM [Przybył K., Gawalek J. i wsp. 2018]. Z kolei przy analizie defektów porażonych ziarniaków rzepaku za pomocą GLCM również skutecznie przeanalizowałem zależności pomiędzy klasami badawczymi [Przybył K., Wawrzyniak J. i wsp. 2020] (Załącznik 4: **poz. II.4.40**). Przy ocenie jakości, stanu i parametrów barwy suszonych batatów na podstawie obrazów (pośrednio poprzez GLCM) również udało się dość dobrze ocenić zależności pomiędzy różnymi klasami [Przybył K., Adamski F. i wsp. 2022] (Załącznik 4: **poz. II.4.31**). Wobec działań na różnych matrycach żywności przy pomocy GLCM zauważyłem także wrażliwość na atrybuty, co może być uzależnione od stopnia struktury wzorca obiektu oraz odległości między pikselami obrazu. Zauważyłem także, że nowoczesne techniki oparte na uczeniu maszynowym i głębokim skuteczniej radzą sobie z rozwiązywaniem zagadnień niż odbywało się to według tradycyjnych technik. W tym badaniu stosując rozpoznawanie proszków z soku porzeczkowego istotny wydawał się dobór metody do wykorzystanych danych tj. zdjęć mikroskopowych. Zastosowanie metaklasyfikatora okazał się najefektywniejszym modelem do identyfikowania proszków z soku porzeczkowego. Zespoły klasyfikatorów wyodrębniając z nich pojedyncze klasyfikatory tj. Random Forest, Decision Tree lub Bagging stały się być lepszym rozwiązaniem niż dotychczasowe narzędzia modelowania neuronowego [Probst P. i wsp. 2019, Zhang T. i wsp. 2022, Yasi M i wsp. 2022, Ogundokum R.O. i wsp. 2022, Mantovani R.G i wsp. 2024]. Ważne jednak jest to, że wybór metody zależy od konkretnego stawianego zadania oraz liczebności przypadków w zbiorze uczącym. Zastosowanie architektury metaklasyfikatora umożliwiło określić w 100% dokładność klasyfikacji dla współczynnika Entropy, w 85% dokładność klasyfikacji dla współczynnika Homogeneity, w 83% dokładność klasyfikacji dla współczynników Energy i Contrast, w 77% dokładność klasyfikacji dla współczynnika Dissimilarity oraz w 70% dokładność klasyfikacji dla współczynnika Coorelation. Dla porównania pojedynczy klasyfikator Random Forest osiągnął istotnie przybliżone wartości dla poszczególnych współczynników tekstury obrazu. Zastosowanie tekstury obrazu oraz algorytmów uczenia maszynowego okazało się skuteczną metodą identyfikowania proszków z soku porzeczkowego. Uzasadnia to przeprowadzenie dalszych badań w kierunku wdrażania metod uczenia maszynowego oceniając piksele obrazu do ewaluacji jakości produktów spożywczych.

Ad. 4.4.5. Explainable AI: machine learning interpretation in blackcurrant powders – publikacja 5 (I.2.5).

W ostatnim czasie wyjaśnialność w uczeniu maszynowym i głębokim staje się istotnym obszarem w zakresie badań oraz zainteresowania, zarówno ze względu na rosnące wykorzystanie metod sztucznej inteligencji, jak i konieczność zrozumienia podejmowanych przez modele decyzji, aby skutecznie optymalizować i kontrolować produkty spożywcze za pomocą nowoczesnych technik. Metody, które zastosowano w tym zagadnieniu badawczym oczekuje się jednocześnie ich zrozumienia tj. wyjaśnialności sztucznej inteligencji (XAI). W celu poznania jakiegoś zagadnienia potrzebne są dane. Te dane mają pewną strukturę. XAI pozwala zrozumieć ideę podejmowania tych decyzji, aby poprzez predykcję danego modelu umieć ocenić wybór danych [**Theissler A. i wsp. 2022, Linardatos P. i wsp. 2020, Liu X i wsp. 2023**].

Niniejsze badania wypełnią lukę w analizie jakości i utrwalania żywności poprzez ocenę struktury morfologicznej mikrocząstek proszków z owoców używając XAI. Procedurę wyodrębniania cech tekstury obrazu dla wybranego rodzaju proszków z soku porzeczkowego określiłem przy pomocy kierunku jak i odległości pikseli na obrazie, zwiększając przy tym stopień zagłębiania danych. W ramach wyodrębniania cech tekstury obrazu przyjąłem 12 kombinacji, które obejmowały odległość o 1, 2 i 3 piksele względem pikseli sąsiadujących oraz uwzględniały kierunek o 0, 90, 180, 270 stopni względem tych pikseli. Wykonałem taką analizę porównawczą pomiędzy pikselami, aby szerzej zrozumieć decyzję modelu względem cech przy rozpoznawania proszków z owoców. Wyodrębnianie cech tekstury wykonano przy pomocy opracowanego autorskiego skryptu w Python ver. 3.10 [**Przybył K., Walkowiak K. i wsp. 2024**] (I.2.4). W pierwszym etapie zaimportowano biblioteki pandas, numpy, skimage oraz os [**Frochte J. i wsp. 2020**]. W kolejnym kroku określono katalog, w którym znajdowały się obrazy różnych rodzajów proszków z soku porzeczkowego (razem 630 zdjęć). Przy pomocy metod greycoprops i greycoprops z biblioteki skimage przygotowałem listę deskryptorów obrazu (glcm_props) tj. entropia, contrast, korelacja, dissimilarity i homogeneity. W następnym kroku zainicjowałem pustą listę do docelowo pozyskiwanych wyników tj. cech tekstury obrazu przy użyciu biblioteki pandas [**Frochte J. i wsp. 2020, Chollet F. 2021**]. Kolejne etapy opierałem na wsadowym przetwarzaniu obrazu tj. wczytanie pliku z określonym rozszerzeniem „.jpg”, utworzenie kopii obrazu, przekonwertowanie obrazu do danych numerycznych przy pomocy funkcji img_as_uint, wyznaczanie parametrów GLCM uwzględniając ustalony kierunek i odległość pomiędzy pikselami obrazu. Ostatni krok zwrócił mi listę wyników z przetwarzania wsadowego obrazów proszków z owoców do pliku z rozszerzeniem „.csv”. Otrzymałem zbiór cech tekstury obrazu dla wybranego rodzaju proszków

z soku porzeczkowego. W zbiorze zawarłem 12 kombinacji względem 5 cech. W sumie otrzymałem 60 różnych deskryptorów tekstury odpowiadających za każdy rodzaj proszków z soku porzeczkowego. Mając na uwadze działania z poprzednich prac badawczych **Przybył K., Walkowiak K. i wsp. 2024 (I.2.4)**, które modele najskuteczniej radziły sobie przy identyfikowaniu m.in. proszków z owoców wybrałem algorytmy uczenia maszynowego takie jak: Decision Tree, Random Forest, AdaBoost, Bagging, KNN oraz LogisticRegression [Shashikant R. i wsp. 2023]. Zaprojektowałem te modele uczenia maszynowego również przy pomocy Python w wersji 3.9. Najpierw zaimportowałem z biblioteki scikit-learn listę klasyfikatorów takich jak: DecisionTreeClassifier, KNeighborsClassifier, LogisticRegression, RandomForestClassifier, AdaBoostClassifier, BaggingClassifier [Pedregosa F. i wsp. 2011, van der Walt S. i wsp. 2014, Hao J. i wsp. 2019]. W kolejnym kroku wykonałem przy pomocy funkcji `train_test_split` podział zbioru w proporcji 70:30 (funkcją `test_size`). Przy inicjalizacji każdego modelu określiłem hiperparametry, które posłużyły do oceny ich wydajności jak i działania. Wydajność modeli określono przy pomocy wskaźników jakości takich jak *accuracy*, *precision*, *recall*, *F1-score*, które wyrażono według wzorów w następujący sposób [Przybył K., Walkowiak K. i wsp. 2024, Chandrasekhar N. i wsp. 2023, Ahn J.M. i wsp. 2019, Sivananthan S. i wsp. 2023] (I.2.4):

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (7)$$

$$Precision = \frac{TP}{TP+FP} \quad (8)$$

$$Recall = \frac{TP}{TP+FN} \quad (9)$$

$$F1 - Score = 2 \cdot \frac{Precision \cdot Recall}{Precision + Recall} \quad (10)$$

W ramach omówienia wyjaśnialności modelu względem cech wykorzystałem technikę LIME [Minh D. i wsp. 2022, Linardatos P. i wsp. 2020, Liu X. i wsp. 2023]. LIME jest jedną z najpopularniejszych metod zrozumienia danych. Idea tej techniki opiera się na lokalnej wyjaśnialności względem pojedynczych przypadków uczących zawartych w zbiorze. Dla ustalonego przypadku możliwe jest oszacowanie wyników [Chollet F. 2021].

W tym etapie pracy przeprowadziłem losowo analizę poszczególnych przypadków uczących względem cech tekstury obrazu, aby umieć zrozumieć podjętą decyzję przez każdy model. Ta metoda w uczeniu maszynowym oszacowała mi prawdopodobieństwo rozpoznawania wybranego rodzaju proszków z soku porzeczkowego przez wybrany model. Dodatkowo podkreśliła, który parametr tekstury obrazu odpowiada za wybrany rodzaj

proszków owocowych. Interpretacja wyników przy pomocy modelu agnostycznego pozwoliła zidentyfikować wybrane cechy dla zaproponowanych modeli uczenia maszynowego.

XAI wyjaśniło, które przypadki uczące zostały przypisane do konkretnych typów proszków z owoców czarnej porzeczki. Niektóre modele jednoznacznie interpretowały proszki z soku porzeczkowego z określonymi cechami tekstury obrazu. To podejście pozwoliło mi zrozumieć modele względem wybranych cech, co przełoży się na adekwatne dobieranie ich w zastosowaniach praktycznych. Ostatnio w literaturze zaobserwowałem, że analiza zrozumienia decyzji przez model staje się być bardzo istotna. Wynika to z faktu m.in. gromadzenia wielu danych i generowania różnych modeli. Warto również zauważyć, że obecne rozwiązania uczenia maszynowego i głębokiego znacząco przyczyniły się do rozwoju wielu zagadnień. Obecne rozwiązania metod SI są szybsze i skuteczniejsze niż dotychczas prowadzone [**Przybył K., Walkowiak K. i wsp. 2024**] (I.2.4). Wielowątkowe SI spowodowało rozwój licznych rozwiązań z użyciem wielu algorytmów [**Visani G. i wsp. 2020, Gracia V. i wsp. 2020, He H. i wsp. 2009**]. To przełożyło się na wykorzystanie XAI, które może przyczynić się do większej przejrzystości, zrozumienia modeli uczenia maszynowego w tych licznych zagadnieniach [**Minh D. i wsp. 2022, Kute D.V. i wsp. 2021, Theissler A i wsp. 2022, Guo W. i wsp. 2020, Rjoub G i wsp. 2023**]. Nadal można zaobserwować potrzebę dalszych badań nad wyjaśnialnością parametrów m.in. w aspekcie proszków owocowych, aby lepiej zrozumieć czynniki wpływające na ich działanie. W przyszłości próba wyjaśnialności m.in. cech tekstury obrazu dla proszków owocowych pozwoli na wykorzystanie ich w praktyce.

W ramach porównania obecnie literatura wykazuje w większości interpretowalność danych przy pomocy wizji komputerowej (obraz) lub przetwarzania języka naturalnego (tekstu) [**Nauta M. i wsp. 2023, Linardatos P. i wsp. 2020, Theissler A i wsp. 2022, Memarzadeh M. i wsp. 2022, Alsaleh M.M i wsp. 2023**]. Nie oznacza to, że zrozumienie danych staje się niemożliwe.

XAI pozwoliło ocenić z jakim prawdopodobieństwem klasyfikuje wybrany model ze względu na rodzaj proszków z soku porzeczkowego. Wykazałem, że najskuteczniej klasyfikowano proszki owocowe przy pomocy modeli z grupy black box tj. Bagging i Random Forest. Najskuteczniejszym modelem okazał się algorytm Bagging_100 osiągając wskaźnik jakości uczenia odpowiednio accuracy, precision, recall, F1-score na poziomie 0,978, 0,980, 0,979, 0,979. Dla porównania spośród zaproponowanych modeli Random Forest model RF7_gini osiągnął również wysoką skuteczność klasyfikowania przy accuracy, precision, recall, F1-score na poziomie 0,968, 0,969, 0,968, 0,968. Biorąc pod uwagę wydajność uczenia modeli na podstawie wskaźnika dokładności powyżej wartości 0,7 osiągnięto ten wynik przez

13 z 14 modeli. XAI pozwoliło dogłębniej przedstawić analizę podejmowania decyzji przez modele uczenia maszynowego na podstawie deskryptorów tekstury. W przyszłości zamierzam prowadzić dalsze działania nad wyjaśnialnością sztucznej inteligencji w aspekcie GLCM, która odgrywa istotną rolę w przetwarzaniu obrazów także dla proszków owocowych. To przełoży się do wdrażania odpowiednich metod sztucznej inteligencji na bazie określonych atrybutów obrazu. Otworzy to możliwości przy analizie i optymalizacji procesów produkcyjnych m.in. monitorując i analizując choćby w trybie on-line proszki owocowe wspomagane SI. Takie działania pozwoli na dokładniejsze określenie struktury proszków owocowych, szczególnie w aspekcie oceny jakościowej tych produktów spożywczych.

4.2.3. Podsumowanie

Przeprowadzone badania, których wyniki opisano w pracy habilitacyjnej, przyniosły zarówno teoretyczne, jak i praktyczne korzyści. Ich realizacja umożliwiła opracowanie nieinwazyjnych rozwiązań o wysokiej wartości badawczej i naukowej. Osiągnięte rezultaty mają znaczenie zarówno dla wiedzy, jak i dla zastosowań praktycznych. Stanowią one nowatorskie narzędzie do poprawy optymalizacji i jakości produktów spożywczych.

Do kluczowych osiągnięć przedstawionych w powyższych badaniach, które stanowią wkład w dyscyplinę naukową – technologia żywności, zaliczam:

- osiągnięcie technologiczne tj. potwierdzenie, że proszki owocowe zawierające 30% nośnika z dodatkiem inuliny wykazują lepsze właściwości jakościowe niż próby z innymi nośnikami. W publikacji 1 (4.4.1) wykazano, że proszki te cechują się wilgotnością poniżej 6%, aktywnością wody na poziomie poniżej 0,25 oraz nie wykazują tendencji do zbrylania się.
- opracowanie sztucznych sieci neuronowych, takich jak Multilayer Perceptron do skutecznej klasyfikacji rodzajów proszków z soku malinowego na podstawie kształtu mikrocząstek, co potwierdzono w publikacji 1 (4.4.1) ich dokładność klasyfikacji wynoszącym 0,99.
- opracowanie sztucznych sieci neuronowych również MLP oraz CNN na podstawie deskryptorów tekstury uzyskanych za pomocą SEM (Skaning Electron Microscopy). Potwierdzono w publikacji 2 (4.4.2) osiągnięcie wysokiej skuteczności klasyfikacji na poziomie 0,96 przy rozpoznawaniu różnych klas proszków z soku malinowego. W ramach porównania CNN w klasyfikacji proszków z soku malinowego przyczyniły się do automatyzacji i szybkości przeprowadzenia etapów w analizie jakości proszków owocowych.

- osiągnięcie technologiczne tj. potwierdzenie, że najniższą wilgotność w próbkach uzyskały proszki z owoców czarnej porzeczki z inuliną, celulozą mikrokryształiczną i błonnikiem. W publikacji 3 (4.4.3) potwierdzono, że sztuczne sieci neuronowe ponownie typu MLP skutecznie klasyfikują na podstawie deskryptorów barwy wybrane typy proszków z soku porzeczkowego.
- opracowanie algorytmów uczenia maszynowego (zespoły klasyfikatorów) takich jak: drzewa decyzyjne (DecisionTree), las losowy (RandomForest), wzmacnianie adaptacyjne (AdaBoost), agregacja ładowania początkowego (Bagging), klasyfikator stochastycznego gradientu (SGDClassifier), RidgeClassifier, perceptron, perceptron wielowarstwowy (MLPPerceptron) i klasyfikacja procesów Gaussa (GaussianProcessClassifier). W publikacji 4 (4.4.4) potwierdzono, że najbardziej efektywnym algorytmem uczenia maszynowego przy klasyfikacji proszków owocowych okazał się algorytm lasów losowych.
- opracowanie metaklasyfikatora, składającego się z 3 różnych algorytmów uczenia maszynowego. W publikacji 4 (4.4.4) potwierdzono, że przy pomocy metaklasyfikatora, udało się wyznaczyć 100% dokładność klasyfikacji dla współczynnika entropii, 85% dokładność klasyfikacji dla współczynnika jednorodności, 83% dokładność klasyfikacji dla współczynników energii i kontrastu, 77% dokładność klasyfikacji dla współczynnika odmienności oraz 70% dokładność klasyfikacji dla współczynnika odmienności.
- osiągnięcie w aspekcie wyjaśnialności proszków owocowych wspomagane sztuczną inteligencją. Wykazano w publikacji 5 (4.4.5), że XAI może ocenić, z jakim prawdopodobieństwem klasyfikuje wybrany model ze względu na rodzaj proszków z soku porzeczkowego. Wykazano, że najskuteczniejszą klasyfikację proszków owocowych uzyskano wykorzystując modele z grupy czarnej skrzynki, tj. Bagging i Random Forest. XAI umożliwiło bardziej dogłębną reprezentację wyznaczania modeli uczenia maszynowego w oparciu o deskryptory tekstury (GLCM). Odpowiednie zrozumienie proszków owocowych wspomagane sztuczną inteligencją umożliwi producentom uzyskanie wysokiej jakości produktów spożywczych.

4.2.4. Wykaz cytowanej literatury

- Alzahrani, M. A., Binnshwan, F. M., Alsulaim, K. B., Mobeirek, O. A., Albakran, N. M., Albawardi, F. A., Almezaini, A. I., Alqahtani, Y. K., Alghuyaythat, W. K. Z., Abunohaiah, I., AlAsmi, R., & Almannie, R. (2023). Effect of Blackcurrant Consumption on the Genitourinary System: A Literature Review. Cureus. <https://doi.org/10.7759/cureus.44181>.

- Grier, D.A., 2013. Edward Feigenbaum. IEEE Annals of the History of Computing. <https://doi.org/10.1109/MAHC.2013.49>
- Dietterich, T. G. 2017.. Steps Toward Robust Artificial Intelligence. AI Magazine, 38(3), 3–24. <https://doi.org/10.1609/aimag.v38i3.2756>
- Kim, H.; Schöneck, D. Kant and Artificial Intelligence; De Gruyter: Berlin, Germany, 2022; pp. 1–290. <https://doi.org/10.1515/9783110706611/MACHINEREADABLECITATION/RIS>.
- Bostrom, N. Superintelligence: Paths, Dangers, Strategies; Oxford University Press: Oxford, UK, 2014.
- Patterson, J.; Gibson, A. Deep Learning a Practitioner's Approach; O'Reilly Media: Sebastopol, CA, USA, 2017.
- Kavdir, I.; Guyer, D.E. Comparison of artificial neural networks and statistical classifiers in apple sorting using textural features. Biosyst. Eng. 2004, 89, 331–344. <https://doi.org/10.1016/j.biosystemseng.2004.08.008>.
- Przybył, K.; Ryniecki, A.; Niedbała, G.; Mueller, W.; Boniecki, P.; Zaborowicz, M.; Koszela, K.; Kujawa, S.; Kozłowski, R.J. Software supporting definition and extraction of the quality parameters of potatoes by using image analysis. In Proceedings of the Eighth International Conference on Digital Image Processing (ICDIP 2016), Chengdu, China, 20–22 May 2016; Falco, C.M., Jiang, X., Eds.; SPIE: Bellingham, WA, USA, 2016; Volume 10033, p. 100332L.
- Tadeusiewicz R., Neural networks: A comprehensive foundation, Control Eng. Pract. 3 (1995) 746–747. [https://doi.org/10.1016/0967-0661\(95\)90080-2](https://doi.org/10.1016/0967-0661(95)90080-2).
- Hameed, K.; Chai, D.; Rassau, A. A comprehensive review of fruit and vegetable classification techniques. Image Vis. Comput. 2018, 80, 24–44. <https://doi.org/10.1016/j.imavis.2018.09.016>.
- Adnan, R.M.; Mostafa, R.R.; Elbeltagi, A.; Yaseen, Z.M.; Shahid, S.; Kisi, O. Development of new machine learning model for streamflow prediction: Case studies in Pakistan. Stoch. Environ. Res. Risk Assess. 2022, 36, 999–1033.
- Bengio, Y. Learning Deep Architectures for AI; Now Publishers Inc.: Delft, The Netherlands, 2009; Volume 2, pp. 1–127. <https://doi.org/10.1561/22000000006>.
- Krohn, J.; Beyleveld, G.; Bassens, A. Deep Learning Illustrated: A Visual, Interactive Guide to Artificial Intelligence; Addison-Wesley Professional: Boston, MA, USA, 2020.
- Liu, R.H. Health-Promoting Components of Fruits and Vegetables in the Diet. Advances in Nutrition 2013, 4, 384S–392S, <https://doi.org/10.3945/an.112.003517>.
- Fenech, M.; Amaya, I.; Valpuesta, V.; Botella, M.A. Vitamin C Content in Fruits: Biosynthesis and Regulation. Front Plant Sci 2019, 9, <https://doi.org/10.3389/fpls.2018.02006>.
- Kader, A.A. Flavor Quality of Fruits and Vegetables. J Sci Food Agric 2008, 88, 1863–1868, <https://doi.org/10.1002/jsfa.3293>.
- Banaś, A.; Korus, A.; Tabaszewska, M. Antioxidant Properties of Low-Sugar Strawberry Jam Enriched with Plant Raw Materials. Polish Journal of Natural Sciences 2018.
- Burton-Freeman, B.M.; Sandhu, A.K.; Edirisinghe, I. Red Raspberries and Their Bioactive Polyphenols: Cardiometabolic and Neuronal Health Links. Advances in Nutrition 2016, 7, 44–65, <https://doi.org/10.3945/an.115.009639>.
- Xu, Y.; Liu, N.; Fu, X.; Wang, L.; Yang, Y.; Ren, Y.; Liu, J.; Wang, L. Structural Characteristics, Biological, Rheological and Thermal Properties of the Polysaccharide and the Degraded Polysaccharide from Raspberry Fruits. Int J Biol Macromol 2019, <https://doi.org/10.1016/j.ijbiomac.2019.03.180>.
- Luo, T.; Miranda-Garcia, O.; Adamson, A.; Sasaki, G.; Shay, N.F. Development of Obesity Is Reduced in High-Fat Fed Mice Fed Whole Raspberries, Raspberry Juice Concentrate, and a Combination of the Raspberry Phytochemicals Ellagic Acid and Raspberry Ketone. J Berry Res 2016, <https://doi.org/10.3233/JBR-160135>.
- Ahmed, N.; Singh, J.; Chauhan, H.; Gupta, P.; Anjum, A.; Kour, H. Different Drying Methods: Their Applications and Recent Advances. International Journal of Food Nutrition and Safety 2013.
- Karam, M.C.; Petit, J.; Zimmer, D.; Baudelaire Djantou, E.; Scher, J. Effects of Drying and Grinding in Production of Fruit and Vegetable Powders: A Review. J Food Eng 2016.
- Samborska, K. Powdered Honey – Drying Methods and Parameters, Types of Carriers and Drying Aids, Physicochemical Properties and Storage Stability. Trends Food Sci Technol 2019.
- Przybył K., Gawalek J., Koszela K., Application of artificial neural network for the quality-based classification of spray-dried rhubarb juice powders, J. Food Sci. Technol. (2023). <https://doi.org/10.1007/s13197-020-04537-9>.

- Przybył K., Gawalek J., Koszela K., Przybył J., Rudzińska M., Gierz Ł., Domian E., Neural image analysis and electron microscopy to detect and describe selected quality factors of fruit and vegetable spray-dried powders—case study: Chokeberry powder, *Sensors* (Switzerland). 19 (2019). <https://doi.org/10.3390/s19204413>.
- Przybył K., Gawalek J., Koszela K., Wawrzyniak J., Gierz Ł., Artificial neural networks and electron microscopy to evaluate the quality of fruit and vegetable spray-dried powders. Case study: Strawberry powder, *Comput. Electron. Agric.* 155 (2018) 314–323. <https://doi.org/10.1016/j.compag.2018.10.033>.
- Przybył K.; Samborska, K.; Koszela, K.; Masewicz, L.; Pawlak, T. Artificial Neural Networks in the Evaluation of the Influence of the Type and Content of Carrier on Selected Quality Parameters of Spray Dried Raspberry Powders. *Measurement* 2021, 186, 110014. <https://doi.org/10.1016/j.measurement.2021.110014>.
- Przybył K.; Walkowiak, K.; Jedlińska, A.; Samborska, K.; Masewicz, Ł.; Biegalski, J.; Pawlak, T.; Koszela, K. Fruit Powder Analysis Using Machine Learning Based on Color and FTIR-ATR Spectroscopy—Case Study: Blackcurrant Powders. *Appl. Sci.* 2023, 13, 9098. <https://doi.org/10.3390/APP13169098>.
- Samborska, K. SPRAY-DRYING OF ENZYMES: CAUSES OF INACTIVATION, METHODS AND MECHANISMS OF STABILIZING THEM. *Zywnosc.Nauka.Technologia.Jakosc/Food.Science.Technology.Quality* 2010, <https://doi.org/10.15193/zntj/2010/73/005-017>.
- Rad, M.R.N.; koohkan, S.; Fanaei, H.R.; Rad, M.R.P. Application of Artificial Neural Networks to Predict the Final Fruit Weight and Random Forest to Select Important Variables in Native Population of Melon (*Cucumis Melo* L.). *Sci Hortic* 2015, 181, 108–112, <http://dx.doi.org/10.1016/j.scienta.2014.10.025>.
- Samborska, K. Suszenie Rozpyłowe w Przemśle Spożywczym. *Postępy Techniki Przetwórstwa Spożywczego* 2008, nr 1, 63–69.
- Sejnowski, T.J.; Cypriański, P. (tłumacz); Wydawnictwo Poltext. *Deep Learning : Głęboka Rewolucja : Kiedy Sztuczna Inteligencja Spotyka Się z Ludzką*. 2019.
- Shishir M.R.I., Chen W., Trends of spray drying: A critical review on drying of fruit and vegetable juices, *Trends Food Sci. Technol.* 65 (2017) 49–67. <https://doi.org/10.1016/j.tifs.2017.05.006>.
- Quek S.Y., Chok N.K., Swedlund P., The physicochemical properties of spray-dried watermelon powders, *Chem. Eng. Process. Process Intensif.* 46 (2007) 386–392. <https://doi.org/10.1016/j.cep.2006.06.020>.
- Etzbach L., Meinert M., Faber T., Klein C., Schieber A., Weber F., Effects of carrier agents on powder properties, stability of carotenoids, and encapsulation efficiency of goldenberry (*Physalis peruviana* L.) powder produced by co-current spray drying, *Curr. Res. Food Sci.* (2020). <https://doi.org/10.1016/j.crfs.2020.03.002>.
- Igual M., Ramires S., Mosquera L.H., Martínez-Navarrete N., Optimization of spray drying conditions for lulo (*Solanum quitoense* L.) pulp, *Powder Technol.* (2014). <https://doi.org/10.1016/j.powtec.2014.02.003>.
- Truong V., Bhandari B.R., Howes T., Optimization of co-current spray drying process of sugar-rich foods. Part I-Moisture and glass transition temperature profile during drying, *J. Food Eng.* (2005). <https://doi.org/10.1016/j.jfoodeng.2004.10.017>.
- Bhandari, B.; Bansal, N.; Zhang, M.; Schuck, P. *Handbook of Food Powders*; Woodhead Publishing Limited: Sawston, UK, 2013; ISBN 978-0-85709-513-8.
- Jedlińska A., Samborska K., Wieczorek A., Wiktor A., Ostrowska-Ligęza E., Jamróz W., Skwarczyńska-Maj K., Kielczewski D., Błażowski Ł., Tułodziecki M., Witrowa-Rajchert D., The application of dehumidified air in rapeseed and honeydew honey spray drying - Process performance and powders properties considerations, *J. Food Eng.* (2019). <https://doi.org/10.1016/j.jfoodeng.2018.10.017>.
- Samborska K., Powdered honey – drying methods and parameters, types of carriers and drying aids, physicochemical properties and storage stability, *Trends Food Sci. Technol.* (2019). <https://doi.org/10.1016/j.tifs.2019.03.019>.
- Ramakrishnan Y., Adzahan N.M., Yusof Y.A., Muhammad K., Effect of wall materials on the spray drying efficiency, powder properties and stability of bioactive compounds in tamarillo juice microencapsulation, *Powder Technol.* (2018). <https://doi.org/10.1016/j.powtec.2017.12.018>.

- Pérez-Reyes M.E., Tang J., Barbosa-Cánovas G.V., Zhu M.J., Influence of water activity and dry-heating time on egg white powders quality, LWT. (2021). <https://doi.org/10.1016/j.lwt.2020.110717>.
- Juárez-Enríquez E., Olivas G.I., Ortega-Rivas E., Zamudio-Flores P.B., Pérez-Vega S., Sepulveda D.R., Water activity, not moisture content, explains the influence of water on powder flowability, LWT. (2019). <https://doi.org/10.1016/j.lwt.2018.10.043>.
- Hartmann M., Palzer S., Caking of amorphous powders - Material aspects, modelling and applications, Powder Technol. (2011). <https://doi.org/10.1016/j.powtec.2010.04.014>.
- Schutyser, M.A.I., Perdana, J., Boom, R.M., Single droplet drying for optimal spray drying of enzymes and probiotics, Trends Food Sci. Technol. (2012). <https://doi.org/10.1016/j.tifs.2012.05.006>.
- Bishop, C.M.C.C.M., Pattern Recognition and Machine Learning, J. Electron. Imaging. 16 (2007) 049901. <https://doi.org/10.1117/1.2819119>.
- Niedbała, G., Application of Artificial Neural Networks for Multi-Criteria Yield Prediction of Winter Rapeseed, Sustainability. 11 (2019) 533. <https://doi.org/10.3390/su11020533>.
- Przybył K., Ryniecki A., Niedbała G., Mueller W., Boniecki P., Zaborowicz M., Koszela K., Kujawa S., Kozłowski R.J., Software supporting definition and extraction of the quality parameters of potatoes by using image analysis, in: Falco C.M., Jiang X. (Eds.), Eighth Int. Conf. Digit. Image Process. (ICDIP 2016), 2016: p. 100332L. <https://doi.org/10.1117/12.2244050>.
- Clausi, D.A. An analysis of co-occurrence texture statistics as a function of grey level quantization. Can. J. Remote Sens. 2002, 28, 45–62.
- Gierz Ł., Przybył K., Koszela K., Duda A., Ostrowicz W., The use of image analysis to detect seed contamination—a case study of triticale, Sensors (Switzerland). (2021). <https://doi.org/10.3390/s21010151>.
- Haralick, R.M. Statistical and Structural Approaches to Texture. Proc. IEEE 1979, 67, 786–804. <https://doi.org/10.1109/PROC.1979.11328>.
- Haralick, R.M.; Shanmugam, K.; Dinstein, I. Textural Features for Image Classification. IEEE Trans. Syst. Man Cybern. 1973, SMC-3, 610–621. <https://doi.org/10.1109/TSMC.1973.4309314>.
- Przybył K.; Boniecki, P.; Koszela, K.; Gierz, Ł.; Łukowski, M. Computer Vision and Artificial Neural Network Techniques for Classification of Damage in Potatoes during the Storage Process. Czech J. Food Sci. 2019, 37, 135–140. <https://doi.org/10.17221/427/2017-CJFS>.
- Howard, A.G.; Zhu, M.; Chen, B.; Kalenichenko, D.; Wang, W.; Weyand, T.; Andreetto, M.; Adam, H. MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications. arXiv 2017, arXiv:1704.04861.
- Le, N.Q.K.; Yapp, E.K.Y.; Ou, Y.-Y.; Yeh, H.-Y. iMotor-CNN: Identifying molecular functions of cytoskeleton motor proteins using 2D convolutional neural network via Chou's 5-step rule. Anal. Biochem. 2019, 575, 17–26. <https://doi.org/10.1016/j.ab.2019.03.017>.
- Ioffe, S.; Szegedy, C. Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift. Proceedings of the 32nd International Conference on Machine Learning, Lille, France, 07–09 July 2015; PMLR 37:448–456.
- Chollet, F. Deep Learning with Python, 2nd ed.; MANNING: Shelter Island, 2021. ISBN: 9781617296864.
- Chollet, F. Keras Documentation. Deep Learning. Working with Python and the Keras library. Helion, 2019; pp 5–368.
- Li, X.; Kong, X.; Liu, Z.; Hu, Z.; Shi, C. A Novel Framework for Early Pitting Fault Diagnosis of Rotating Machinery Based on Dilated CNN Combined With Spatial Dropout. IEEE Access 2021, 9, 29243–29252. <https://doi.org/10.1109/ACCESS.2021.3058993>.
- Zhao, W. A Broyden–Fletcher–Goldfarb–Shanno algorithm for reliability-based design optimization. Appl. Math. Model. 2021, 92, 447–465. <https://doi.org/10.1016/j.apm.2020.11.012>.
- Nelli, F.; Nelli, F. Deep Learning with TensorFlow. In Python Data Analytics; Apress, Berkeley, CA. 2018; pp 49–486 https://doi.org/10.1007/978-1-4842-3913-1_9.
- Wongphan, P.; Harnkarnsujarit, N. Characterization of starch, agar and maltodextrin blends for controlled dissolution of edible films. Int. J. Biol. Macromol. 2020, 156, 80–93. <https://doi.org/10.1016/j.ijbiomac.2020.04.056>.
- Naumann, D. FT-IR and FT-NIR Raman spectroscopy in biomedical research. In Proceedings of the AIP Conference Proceedings; AIP: Melville, NY, USA, 1998; Volume 430, pp. 96–109.

- Ramírez-Hernández, A.; Aguilar-Flores, C.; Aparicio-Saguilán, A. Fingerprint analysis of FTIR spectra of polymers containing vinyl acetate. *DYNA* 2019, 86, 198–205, <https://doi.org/10.15446/dyna.v86n209.77513>.
- Melanie, H.; Susilowati, A.; Iskandar, Y.M.; Lotulung, P.D.; Andayani, D.G.S. Characterization of Inulin from Local Red Dahlia (*Dahlia* Sp. L) Tubers by Infrared Spectroscopy. *Procedia Chem* 2015, 16, 78–84, <https://doi.org/10.1016/j.proche.2015.12.027>.
- Hall-Beyer, M; GLCM Texture: A Tutorial v. 3.0 March 2017 | Enhanced Reader. University of Calgary, Canada, 2017, pp 2-75, <https://doi.org/10.13140/RG.2.2.12424.21767>
- Boel, E.; Koekoekx, R.; Dedroog, S.; Babkin, I.; Vetrano, M.R.; Clasen, C.; Van den Mooter, G. Unraveling Particle Formation: From Single Droplet Drying to Spray Drying and Electrospraying. *Pharmaceutics* 2020, 12, 625, <https://doi.org/10.3390/pharmaceutics12070625>.
- Wallace, T.C.; Bailey, R.L.; Blumberg, J.B.; Burton-Freeman, B.; Chen, C. y. O.; Crowe-White, K.M.; Drewnowski, A.; Hooshmand, S.; Johnson, E.; Lewis, R.; et al. Fruits, Vegetables, and Health: A Comprehensive Narrative, Umbrella Review of the Science and Recommendations for Enhanced Public Policy to Improve Intake. *Crit Rev Food Sci Nutr* 2020, 60.
- Baranowska H.M., Masewicz Ł., Kowalczewski P.Ł., Lewandowicz G., Piątek M., Kubiak P., Water properties in pâtés enriched with potato juice, *Eur. Food Res. Technol.* (2018). <https://doi.org/10.1007/s00217-017-2965-4>.
- Przybył K.; Koszela, K. Applications MLP and Other Methods in Artificial Intelligence of Fruit and Vegetable in Convective and Spray Drying. *Applied Sciences* 2023, 13, 2965, <https://doi.org/10.3390/app13052965>.
- Ray, A.K.; Bird, P.B.; Iacobucci, G.A.; Clark, B.C. Functionality of Gum Arabic. Fractionation, Characterization and Evaluation of Gum Fractions in Citrus Oil Emulsions and Model Beverages. *Top Catal* 1995, [https://doi.org/10.1016/S0268-005X\(09\)80274-9](https://doi.org/10.1016/S0268-005X(09)80274-9).
- Fernandes R.V.D.B., Borges S.V., Botrel D.A., Gum arabic/starch/maltodextrin/inulin as wall materials on the microencapsulation of rosemary essential oil, *Carbohydr. Polym.* (2014). <https://doi.org/10.1016/j.carbpol.2013.09.083>.
- Przybył K.; Masewicz, Ł.; Koszela, K.; Duda, A.; Szychta, M.; Gierz, Ł. An MLP artificial neural network for detection of the degree of saccharification of Arabic gum used as a carrier agent of raspberry powders. In *Proceedings of the Thirteenth International Conference on Digital Image Processing*; Sinagapore, Singapore, 20-23 May 2021; Jiang, X., Fujita, H., Eds.; SPIE: Bellingham, WA, USA, 2021; Volume 11878, p. 93.
- Jedlińska, A.; Samborska, K.; Wiecezorek, A.; Wiktor, A.; Ostrowska-Ligęza, E.; Jamróz, W.; Skwarczyńska-Maj, K.; Kielczewski, D.; Błażowski, Ł.; Tułodziecki, M.; et al. The Application of Dehumidified Air in Rapeseed and Honeydew Honey Spray Drying - Process Performance and Powders Properties Considerations. *J Food Eng* 2019, <https://doi.org/10.1016/j.jfoodeng.2018.10.017>.
- Samborska, K., Jedlińska, A., Wiktor, A., Derewiaka, D., Wołosiak, R., Matwijczuk, A., Jamróz, W., Skwarczyńska-Maj, K., Kielczewski, D., Błażowski, Ł., Tułodziecki, M., Witrowa-Rajchert, D., The Effect of Low-Temperature Spray Drying with Dehumidified Air on Phenolic Compounds, Antioxidant Activity, and Aroma Compounds of Rapeseed Honey Powders, *Food Bioprocess Technol.* (2019). <https://doi.org/10.1007/s11947-019-02260-8>.
- Yu, M.; Chen, Y.; Liu, Y.; Xu, Y.; Wang, B. Efficient Polysaccharides from *Crinum Asiaticum* L.'s Structural Characterization and Anti-Tumor Effect. *Saudi J Biol Sci* 2019, 26, <https://doi.org/10.1016/j.sjbs.2019.09.017>.
- Aly, A.A.; Ali, H.G.M.; Eliwa, N.E.R. Phytochemical Screening, Anthocyanins and Antimicrobial Activities in Some Berries Fruits. *Journal of Food Measurement and Characterization* 2019, 13, <https://doi.org/10.1007/s11694-018-0005-0>.
- Ying, D.Y.; Hlaing, M.M.; Lerisson, J.; Pitts, K.; Cheng, L.; Sanguansri, L.; Augustin, M.A. Physical Properties and FTIR Analysis of Rice-Oat Flour and Maize-Oat Flour Based Extruded Food Products Containing Olive Pomace. *Food Research International* 2017, 100, <https://doi.org/10.1016/j.foodres.2017.07.062>.
- Bashir, D.; Montañez, G.D.; Sehra, S.; Segura, P.S.; Lauw, J. An Information-Theoretic Perspective on Overfitting and Underfitting. In *AI 2020: Advances in Artificial Intelligence: 33rd Australasian Joint Conference*, AI 2020, Canberra, ACT, Australia, 29–30 November 2020; Springer International

- Publishing: Cham, Switzerland, 2020; Volume 12576 LNAI, pp. 347–358. https://doi.org/10.1007/978-3-030-64984-5_27.
- Dubey, S.R.; Singh, S.K.; Chaudhuri, B.B. Activation Functions in Deep Learning: A Comprehensive Survey and Benchmark. *Neurocomputing* 2022, 503.
 - Singh, P.; Singh, N. Blockchain With IoT and AI. In *Research Anthology on Convergence of Blockchain, Internet of Things, and Security*; IGI Global, 2022; pp. 1315–1330. <https://doi.org/10.4018/978-1-6684-7132-6.ch070>
 - Mavani, N.R.; Ali, J.M.; Othman, S.; Hussain, M.A.; Hashim, H.; Rahman, N.A. Application of Artificial Intelligence in Food Industry—A Guideline. *Food Eng. Rev.* 2022, 14, 134–175. <https://doi.org/10.1007/s12393-021-09290-z>.
 - Thomas, A.; Reddy, K.S.; Alexander, D.; Prabhakaran, P. (Eds) *Climate Change and the Health Sector*; Routledge India: London, UK, 2021. <https://doi.org/10.4324/9781003190516>.
 - Khan, R.; Kumar, S.; Dhingra, N.; Bhati, N. The Use of Different Image Recognition Techniques in Food Safety: A Study. *J. Food Qual.* 2021, 2021, 7223164. <https://doi.org/10.1155/2021/7223164>.
 - Tayi, A. The Internet of Things Is Digitizing and Transforming Science. *SLAS Technol.* 2018, 23, 407–411. <https://doi.org/10.1177/2472630318788533>.
 - Vermesan, O. *Artificial Intelligence for Digitising Industry—Applications*; Taylor & Francis Ltd.: London, UK, 2022. <https://doi.org/10.1201/9781003337232>.
 - Saifullah, M.; Yusof, Y.A.; Chin, N.L.; Aziz, M.G. Physicochemical and Flow Properties of Fruit Powder and Their Effect on the Dissolution of Fast Dissolving Fruit Powder Tablets. *Powder Technol.* 2016, 301, 396–404. <https://doi.org/10.1016/j.powtec.2016.06.035>.
 - Yamashkin, S.; Yamashkin, A.; Radovanović, M.; Petrović, M.; Yamashkina, E. Classification of Metageosystems by Ensembles of Machine Learning Models. *Int. J. Eng. Trends Technol.* 2022, 70, 258–268. <https://doi.org/10.14445/22315381/IJETT-V70I9P226>.
 - Gierz, Ł.; Przybył, K. Texture Analysis and Artificial Neural Networks for Identification of Cereals—Case Study: Wheat, Barley and Rape Seeds. *Sci. Rep.* 2022, 12, 19316. <https://doi.org/10.1038/s41598-022-23838-x>.
 - Przybył K.; Wawrzyniak, J.; Koszela, K.; Adamski, F.; Gawrysiak-Witulska, M. Application of Deep and Machine Learning Using Image Analysis to Detect Fungal Contamination of Rapeseed. *Sensors* 2020, 20, 7305. <https://doi.org/10.3390/s20247305>.
 - Przybył K.; Adamski, F.; Wawrzyniak, J.; Gawrysiak-Witulska, M.; Stangierski, J.; Kmiecik, D. Machine and Deep Learning in the Evaluation of Selected Qualitative Characteristics of Sweet Potatoes Obtained under Different Convective Drying Conditions. *Appl. Sci.* 2022, 12, 7840. <https://doi.org/10.3390/app12157840>.
 - Probst, P.; Wright, M.N.; Boulesteix, A.L. Hyperparameters and Tuning Strategies for Random Forest. *Wiley Interdiscip. Rev. Data Min. Knowl. Discov.* 2019, 9, e1301. <https://doi.org/10.1002/widm.1301>.
 - Zhang, T.; Fu, Q.; Wang, H.; Liu, F.; Wang, H.; Han, L. Bagging-Based Machine Learning Algorithms for Landslide Susceptibility Modeling. *Nat. Hazards* 2022, 110, 823–846. <https://doi.org/10.1007/s11069-021-04986-1>.
 - Ogundokun, R.O.; Maskeliunas, R.; Misra, S.; Damaševičius, R. Improved CNN Based on Batch Normalization and Adam Optimizer. In *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*; Springer International Publishing: Cham, Switzerland, 2022; Volume 13381 LNCS, pp. 593–604. https://doi.org/10.1007/978-3-031-10548-7_43.
 - Mantovani, R.G.; Horváth, T.; Rossi, A.L.D.; Cerri, R.; Junior, S.B.; Vanschoren, J.; de Carvalho, A.C.P. de L.F. Better Trees: An Empirical Study on Hyperparameter Tuning of Classification Decision Tree Induction Algorithms. *Data Min. Knowl. Discov.* 2024 <https://doi.org/10.1007/s10618-024-01002-5>.
 - Minh, D.; Wang, H.X.; Li, Y.F.; Nguyen, T.N. Explainable Artificial Intelligence: A Comprehensive Review. *Artif. Intell. Rev.* 2022, 55, 3503–3568. <https://doi.org/10.1007/s10462-021-10088-y>.
 - Kute, D.V.; Pradhan, B.; Shukla, N.; Alamri, A. Deep Learning and Explainable Artificial Intelligence Techniques Applied for Detecting Money Laundering—A Critical Review. *IEEE Access* 2021, 9, 82300–82317. <https://doi.org/10.1109/ACCESS.2021.3086230>.
 - Theissler, A.; Spinnato, F.; Schlegel, U.; Guidotti, R. Explainable AI for Time Series Classification: A Review, Taxonomy and Research Directions. *IEEE Access* 2022, 10, 100700–100724. <https://doi.org/10.1109/ACCESS.2022.3207765>.

- Guo, W.; Zhang, Z.; Yu, W.; Sun, X. Perspective on Explainable SAR Target Recognition. *J. Radars* 2020, 9, 462–476. <https://doi.org/10.12000/JR20059>.
- Rjoub, G.; Bentahar, J.; Abdel Wahab, O.; Mizouni, R.; Song, A.; Cohen, R.; Otrok, H.; Mourad, A. A Survey on Explainable Artificial Intelligence for Cybersecurity. *IEEE Trans. Netw. Serv. Manag.* 2023, 20, 5115–5140. <https://doi.org/10.1109/TNSM.2023.3282740>.
- Nauta, M.; Trienes, J.; Pathak, S.; Nguyen, E.; Peters, M.; Schmitt, Y.; Schlötterer, J.; Van Keulen, M.; Seifert, C. From Anecdotal Evidence to Quantitative Evaluation Methods: A Systematic Review on Evaluating Explainable AI. *ACM Comput. Surv.* 2023, 55, 1–42. <https://doi.org/10.1145/3583558>.
- Linardatos, P.; Papastefanopoulos, V.; Kotsiantis, S. Explainable AI: A Review of Machine Learning Interpretability Methods. *Entropy* 2020, 23, 18. <https://doi.org/10.3390/e23010018>.
- Frochte, J. Python, NumPy, SciPy Und Matplotlib—In a Nutshell. In *Maschinelles Lernen*; Carl Hanser Verlag GmbH & Co. KG: München, Germany, 2020; pp. 38–77.
- Przybył K.; Walkowiak, K.; Kowalczewski, P.Ł. Efficiency of Identification of Blackcurrant Powders Using Classifier Ensembles. *Foods* 2024, 13, 697. <https://doi.org/10.3390/foods13050697>.
- Shashikant, R.; Chetankumar, P. Predictive Model of Cardiac Arrest in Smokers Using Machine Learning Technique Based on Heart Rate Variability Parameter. *Appl. Comput. Inform.* 2023, 19, 174–185. <https://doi.org/10.1016/j.aci.2019.06.002>.
- Pedregosa, F.; Varoquaux, G.; Gramfort, A.; Michel, V.; Thirion, B.; Grisel, O.; Blondel, M.; Prettenhofer, P.; Weiss, R.; Dubourg, V.; et al. Scikit-Learn: Machine Learning in Python. *J. Mach. Learn. Res.* 2011, 12, 2825–2830.
- van der Walt, S.; Schönberger, J.L.; Nunez-Iglesias, J.; Boulogne, F.; Warner, J.D.; Yager, N.; Guillaud, E.; Yu, T. Scikit-Image: Image Processing in Python. *PeerJ* 2014, 2, e453. <https://doi.org/10.7717/peerj.453>.
- Hao, J.; Ho, T.K. Machine Learning Made Easy: A Review of Scikit-Learn Package in Python Programming Language. *J. Educ. Behav. Stat.* 2019, 44, 348–361. <https://doi.org/10.3102/1076998619832248>.
- Chandrasekhar, N.; Peddakrishna, S. Enhancing Heart Disease Prediction Accuracy through Machine Learning Techniques and Optimization. *Processes* 2023, 11, 1210. <https://doi.org/10.3390/pr11041210>.
- Ahn, J.M.; Kim, S.; Ahn, K.S.; Cho, S.H.; Kim, U.S. Accuracy of Machine Learning for Differentiation between Optic Neuropathies and Pseudopapilledema. *BMC Ophthalmol.* 2019, 19, 178. <https://doi.org/10.1186/s12886-019-1184-0>.
- Sivanantham, S.; Mohanraj, V.; Suresh, Y.; Senthilkumar, J. Rule Precision Index Classifier: An Associative Classifier with a Novel Pruning Measure for Intrusion Detection. *Pers. Ubiquitous Comput.* 2023, 27, 1–9. <https://doi.org/10.1007/s00779-021-01599-0>.
- Visani, G.; Bagli, E.; Chesani, F.; Poluzzi, A.; Capuzzo, D. Statistical Stability Indices for LIME: Obtaining Reliable Explanations for Machine Learning Models. *J. Oper. Res. Soc.* 2022, 73, 91–101. <https://doi.org/10.1080/01605682.2020.1865846>.
- García, V.; Sánchez, J.S.; Marqués, A.I.; Florencia, R.; Rivera, G. Understanding the Apparent Superiority of Over-Sampling through an Analysis of Local Information for Class-Imbalanced Data. *Expert. Syst. Appl.* 2020, 158, 113026. <https://doi.org/10.1016/j.eswa.2019.113026>.
- He, H.; Garcia, E.A. Learning from Imbalanced Data. *IEEE Trans Knowl Data Eng* 2009, 21, 1263–1284. <https://doi.org/10.1109/TKDE.2008.239>.
- Alsaleh, M.M.; Allery, F.; Choi, J.W.; Hama, T.; McQuillin, A.; Wu, H.; Thygesen, J.H. Prediction of Disease Comorbidity Using Explainable Artificial Intelligence and Machine Learning Techniques: A Systematic Review. *Int. J. Med. Inf.* 2023, 175, 105088. <https://doi.org/10.1016/j.ijmedinf.2023.105088>.
- Memarzadeh, M.; Akbari Asanjan, A.; Matthews, B. Robust and Explainable Semi-Supervised Deep Learning Model for Anomaly Detection in Aviation. *Aerospace* 2022, 9, 437. <https://doi.org/10.3390/aerospace9080437>.
- Data of Analysis of the Influence of Microparticle Morphology on the Qualitative state of Spray-Dried Fruit with the Use of Deep Learning. <https://doi.org/10.18150/J6R7UY>.

4.3.Omówienie pozostałych osiągnięć naukowych

Moje badania naukowe po uzyskaniu stopnia naukowego doktora koncentrowały się na kilku obszarach badawczych takich jak:

- 4.3.1.** unowocześnienie oprogramowania „PIDsystem” wspomagającego definiowanie i ekstrakcję parametrów jakościowych za pomocą przetwarzania i analizy obrazu.
- 4.3.2.** ocena stanu jakościowego suszonych rozpyłowo soków: truskawkowego, aroniowego i rabarbarowego z wykorzystaniem komputerowej analizy obrazu oraz sztucznych sieci neuronowych.
- 4.3.3.** ocena stanu jakościowego suszonego konwekcyjnie suszu truskawkowego z wykorzystaniem technik dźwięku i sztucznych sieci neuronowych.
- 4.3.4.** ocena jakości nasion zbóż i kawy z wykorzystaniem analizy obrazu i sztucznych sieci neuronowych.
- 4.3.5.** ocena lepkości pektyn poprzez uczenie maszynowe i analizy fizyczne, w celu poprawy jakości, zwiększenia wydajności oraz minimalizacji strat w przemyśle spożywczym i farmaceutycznym.

Ad. 4.3.1. Po uzyskaniu stopnia doktora, w 2016 roku, wykorzystałem oraz zmodyfikowałem o nowe funkcjonalności autorski system informatyczny Przybył Image Detector system („PIDsystem”) wspomagający analizę i interpretację deskryptorów obrazu. System komputerowy został zaprojektowany w ramach mojej pracy doktorskiej w środowisku programistycznym Microsoft Visual Studio. Visual Studio obsługuje różne języki programowania, w tym C#, który został użyty do napisania tego programu. Oprogramowanie autorskie korzysta także z otwartych bibliotek AForge.NET (<http://www.aforge.net.com/>) i OpenCV (<http://opencv.org/>), oferujących funkcje analizy i przetwarzania obrazów. W ramach rozwoju po doktoracie rozbudowałem program „PIDsystem” o metody, które mają możliwość wygenerowania skryptu obliczającego cechy związane z teksturą obrazu. Powyższy skrypt można bezpośrednio zaimportować do środowiska MATLAB, korzystając z biblioteki Haralick dla GLCM, w celu wyznaczenia deskryptorów. „PIDsystem” charakteryzuje się wszechstronnością i szybkością działania podczas przetwarzania serii zdjęć cyfrowych. „PIDsystem” pozwala na przygotowanie danych numerycznych do oceny parametrów jakościowych produktów spożywczych w celu wytworzenia zbioru treningowego dla modeli neuronowych. Wyniki tych badań przedstawiłem na konferencji i opublikowałem w materiale konferencyjnym (Załącznik 4: **poz. II.4.41, II.4.58, II.7.2.28**).

Ad. 4.3.2. W latach 2017-2018 będąc kierownikiem zadania badawczego 507.752.4, finansowanego z dotacji służącej rozwojowi młodego naukowca Uniwersytetu Przyrodniczego w Poznaniu (Załącznik 4: **poz. II.9.4**), przeprowadziłem działania mające na celu porównanie obrazów mikroskopowych z obrazami cyfrowymi, które zweryfikowały poprawność wybranych parametrów, takich jak: barwa, współczynniki kształtu i tekstura obrazu na podstawie neuronowej analizy obrazów suszonego rozpyłowo soku truskawkowego. Badania przeprowadziłem, bazując na analizie i rozpoznawaniu obrazów opisujących klasy jakościowe proszków z soku truskawkowego otrzymywanych w procesie suszenia przemysłowego, które były realizacją mojej koncepcji.

Zaproponowana przeze mnie metodyka badawcza składa się ze ściśle określonych etapów postępowania. W pierwszej fazie nawiązałem współpracę z przedsiębiorstwem, które udostępniło próbki różnych klas jakościowych proszków z soku truskawkowego dla potrzeb zadania badawczego. W kolejnym etapie realizacji moich badań przeprowadziłem analizę materiału badawczego tj. proszków z soku truskawkowego. Wykonałem wybrane analizy fizyczne opisujące właściwości proszków owocowych (wilgotność, aktywność wody, gęstość nasypową luźną, gęstość nasypową ubitą, współczynnik Hausnera (HR) oraz Carra (Ic) opisujący sypkość proszków, rozmiar mikrocząstek, barwę $L^*a^*b^*$). Wykonałem zdjęcia cyfrowe przy użyciu autorskiego stanowiska pomiarowo-badawczego do zbierania danych empirycznych. Celem było zbudowanie bazy danych graficznych na podstawie bitmap substancji proszkowych. Przy użyciu oprogramowania „PIDsystem” wyznaczyłem wybrane deskryptory obrazu modeli przestrzeni barw RGB, HSB, YCbCr, YUV, YIQ oraz tekstury obrazu z wykorzystaniem GLCM. Zaznaczam, że analizowałem struktury mikro i makro suszonego rozpyłowo soku truskawkowego przy użyciu skaningowej mikroskopii elektronowej oraz kamery cyfrowej. Oprócz analizy tekstury za pomocą GLCM, wykorzystałem również tekstury obrazu według metody Laws. Dane numeryczne pozyskane ze zdjęć cyfrowych pozwoliły mi utworzyć zbiory uczące. Utworzenie zbiorów uczących wykorzystałem do projektowania i wykonywania modeli neuronowych z wykorzystaniem w środowisku STATISTICA.

W wyniku powyższych badań wykazałem, że analiza właściwości tekstury pozwoliła skutecznie określić materiał badany składający się z różnych klas jakościowych suszonych rozpyłowo proszków soku truskawkowego. Analiza sztucznych sieci neuronowych wykazała, że istnieją odpowiednie modele pod względem najniższej wartości błędu średniokwadratowego, tj. Root Mean Square (RMS), oraz skuteczność klasyfikująca niewłaściwą strukturę mikrocząstek w ocenie jakości proszków z soku truskawkowego. Analiza

głównych składników metodą PCA wykazała prawidłowość wykorzystania parametrów tekstury, które dobrze korelują z funkcją koloru w technice komputerowej analizie obrazu. Zauważono silne skorelowanie między parametrami tekstury obrazu w skaningowej mikroskopii elektronowej. Istotna korelacja dotyczyła rozpoznania struktury mikrocząstek pod względem kształtu, takich jak współczynnik Ferreta, współczynnik okrągłości lub współczynnik kołowości w mikroskopii elektronowej. Wyniki te potwierdziły, że poznanie klas jakościowych proszków owocowych może stanowić podstawę do ich szybkiej oceny jakości w przemysłowym suszeniu rozpyłowym. Ogólnie porównanie przy pomocy metod obrazowania pokazuje, że stopień powiększenia proszków pod względem struktury cząsteczkowej ma wpływ na rozpoznawanie obrazów, co może istotnie wpłynąć na klasyfikację klas jakościowych. Wykorzystanie tekstur Laws oraz technik analizy obrazu, w tym sztucznych sieci neuronowych, umożliwiło skuteczne rozpoznanie jakości badanego materiału, tj. suszonego rozpyłowo soku truskawkowego o zróżnicowanej jakości (barwie, wielkości mikrocząstek, teksturze). Wyniki tych badań opublikowałem w materiale konferencyjnym oraz czasopiśmie naukowym (Załącznik 4: **poz. II. 4.48, II. 4.47**).

W 2019 roku skoncentrowałem się na zbadaniu możliwości wykorzystania komputerowej analizy obrazu i modelowania neuronowego do oceny wybranych wyróżników jakości suszonego rozpyłowo soku aroniowego. Celem pracy była identyfikacja jakościowa proszków z soku aroniowego ze względu na ich siłę barwienia, bioaktywność, a także satysfakcjonującą technologicznie syropowość proszku. Przedstawiłem (Załącznik 4: **poz. II. 4.46**) koncepcję, metodykę oraz opracowałem wyniki tj. zaprojektowałem i wykonałem modele neuronowe z wykorzystaniem technik wizyjnych wspieranych przez urządzenia takie jak kamera cyfrowa, a także mikroskop elektronowy. Przeprowadziłem analizę statystyczną tj. wykonałem redukcję rozmiaru zmiennych wejściowych za pomocą analizy PCA, która wpłynęła na usprawnienie procesów uczenia zbiorów danych, zwiększając tym samym skuteczność identyfikacji proszków z owoców aronii zawartych na zdjęciach cyfrowych, co pokazują wyniki przeprowadzonych badań. Skuteczność rozpoznawania obrazów prezentowana jest przez zdolności klasyfikujące, a także niski błąd średniokwadratowy (RMSE), dla którego najlepsze wyniki osiąga typologia sieci typu MLP. Wybrane sieci typu MLP charakteryzują się najwyższym stopniem klasyfikacji na poziomie 0,99 i RMSE na poziomie co najwyżej 0,11. Badania nad jakością suszonego soku z aronii wykorzystujące techniki wizyjne pokazały, że najefektywniejszym narzędziem do rozpoznawania klas jakości jest stosowanie współczynnika koloru w przestrzeni barw YCbCr. Analiza PCA wskazała, że najmocniejsza korelacja występuje dla składowej Y w modelu YCbCr. Modele neuronowe uwzględniające

współczynniki kształtu potwierdziły, że efektywność rozpoznawania mikrocząstek jest silnie zależna od ich średnicy. Redukcja wymiarów wejściowych w analizie PCA poprawiła efektywność rozpoznawania obrazów cyfrowych oraz obrazów SEM, co z kolei podniosło poziom prób w modelach neuronowych. Wyniki tych badań przedstawiłem na konferencji oraz opublikowałem w czasopiśmie naukowym (Załącznik 4: **poz. II. 4.46, II. 7.2.27**).

Również opublikowałem wyniki badań związane z oceną jakości proszków z soku rabarbarowego wspomagane sztuczną inteligencją (**Załącznik 4: poz. II.4.27**). W ramach zadania badawczego opracowałem model neuronowy umożliwiający klasyfikację proszków z soku rabarbarowego na podstawie danych graficznych uzyskanych z map bitowych otrzymanych w procesie suszenia rozpyłowego. Model neuronowy został opracowany w topologii perceptronu wielowarstwowego. Zmienne wejściowe zostały wyrażone w postaci 46 deskryptorów obrazu opartych na modelach przestrzeni barw: RGB, YCbCr, HSV (B) i HSL. Opracowałem analizę wrażliwości zmiennych wejściowych i analizę składowych głównych określając przy tym poziom istotności każdego deskryptora. Otrzymałem optymalny model o najniższej wartości błędu średniokwadratowego, na poziomie 0,04, który zawierał 46 neuronów w warstwie wejściowej, 11 neuronów w warstwie ukrytej oraz 10 neuronów w warstwie wyjściowej. Uzyskane wyniki pozwoliły mi wykazać, że siła barwienia (deskryptory barwy) miała wpływ na efektywne różnicowanie materiału badawczego składającego się z suszonych rozpyłowo proszków z soku rabarbarowego o różnych poziomach zawartości soku suszonego: 30, 40 i 50% oraz wysokim („H”) i niskim („L”) poziomie scukrzenia wybranego nośnika (maltodekstryny ziemniaczanej). Wyniki tych badań przedstawiłem także na konferencji (Załącznik 4: **poz. II.7.2.26**).

Ad. 4.3.3. Zaproponowałem klasyfikację suszonych truskawek poprzez analizę akustyczną za pomocą sztucznych sieci neuronowych. W ramach pracy przedstawiłem koncepcję, metodykę oraz opracowałem wyniki, wykorzystując falę akustyczną jako źródło zaburzeń (drgania mechaniczne), które rozchodziły się we wszystkich kierunkach na całej powierzchni suszonej truskawki, w jej określonym obszarze. Obszar przestrzeni, w którym występuje fala akustyczna, określany jest jako pole akustyczne. Gdy drgająca powierzchnia - na przykład powierzchnia płaska - staje się źródłem fal akustycznych, wówczas można zaobserwować przemieszczanie się fal powierzchniowych. Dla dowolnego kształtu powierzchni suszonego owocu truskawki, sygnał przemieszczających się fal przyjmuje postać narzuconą przez tę nieregularną powierzchnię. W pracy zbadałem skuteczność rozpoznawania dwóch procesów w procesie suszenia konwekcyjnego na podstawie sygnału akustycznego wspomagane sieciami neuronowymi. Zmienne wejściowe określały deskryptory takie jak częstotliwość (Hz) oraz

poziom głośności dźwięku (dB). W trakcie badań porównałem stopień chrupkości względem stopnia dojrzałości. Wyniki pokazały, że optymalnym modelem neuronowym pod względem najniższej wartości średniej kwadratowej okazała się sieć typu MLP z techniką zrzucania pojedynczych owoców do wody (dane zawarte w zbiorze uczącym Z2). Wyniki potwierdzają, że wybór metody może mieć wpływ na skuteczność rozpoznawania suszonych owoców truskawek, a także może być podstawą do stworzenia skutecznego i szybkiego narzędzia analitycznego, które jest w stanie analizować stopień dojrzałości owoców, w tym ich kruchość w przemysłowym procesie suszenia owoców. Podsumowując, w badaniach nad suszeniem truskawek zaobserwowałem, że sieci neuronowe, zwłaszcza MLP o architekturze 2:14:1 dla typu Z2, osiągnęły wysoką zdolność klasyfikacyjną, uzyskując błąd RMS na poziomie 0,09 i MAPE na poziomie około 10%. Wykorzystanie sygnałów akustycznych wsparte metodą uczenia maszynowego pozwoliło na szybkie i skuteczne rozpoznawanie klasy jakości materiału badanego, szczególnie jego chrupkości w różnych warunkach jakościowych. Suszenie jest uważane za jedną z najbezpieczniejszych metod konserwacji żywności, umożliwiającą zachowanie jakości produktów dzięki szerokiemu zastosowaniu suszarek konwekcyjnych, niezależnie od ich kształtu czy stanu fizycznego. Wyniki tych badań przedstawiłem w rozdziale w monografii oraz opublikowałem w czasopiśmie naukowym (Załącznik 4: **poz. II.2.10, II.4.39**).

Ad. 4.3.4. We współpracy z zespołem podjęliśmy prace nad oceną nasion rzepaku pozyskanych w procesie eksperymentów przechowalniczych przy zróżnicowanej wilgotności (12% i 16% wilgotności nasion) i temperaturze (25 i 30 °C). Próbki charakteryzowały się różnym poziomem zanieczyszczenia grzybami strzępkowymi. W celu uzyskania danych graficznych przeprowadziłem analizę morfologii nasion rzepaku przy użyciu mikroskopii. Uzyskane dane wykorzystałem do wykonania zbiorów treningowych, walidacyjnych i testowych. W procesie projektowania i wykonania modelu neuronowego skorzystałem z CNN, sieci typu MLP oraz sieci typu RBF. Porównywane klasyfikatory opracowałem w oparciu o środowiska Tensorflow i Statistica. Na podstawie przeprowadzonych badań stwierdziłem z zespołem, że błąd klasyfikacji zanieczyszczenia grzybami w nasionach rzepaku przy użyciu głębokiego uczenia i uczenia maszynowego wynosił od 14% do 21% na zbiorze testowym. Sieć CNN osiągnęła dokładność klasyfikacji na poziomie 0,89, co było porównywalne z wynikiem uzyskanym przez sieć MLP. Sieć RBF uzyskała nieco niższy wynik dokładności (0,85). Wykazałem, że topologie sieci CNN i MLP były skuteczniejsze w identyfikacji stanu zanieczyszczenia grzybami nasion rzepaku niż topologia sieci RBF. Redukcja liczby zmiennych wejściowych w sieci MLP miała pozytywny wpływ na efektywność rozpoznawania

stanu jakości nasion rzepaku. Wyniki te mogą mieć istotne znaczenie dla przemysłu rolniczego i spożywczego, wpływając na kontrolę jakości surowców roślinnych. Wyniki tych badań opublikowałem w czasopiśmie naukowym (Załącznik 4: **poz. II.4.40**).

Oceeniłem próbki nasion pszenżyta o różnej jakości. Celem badania było wykorzystanie sieci neuronowych do identyfikacji zanieczyszczeń w nasionach pszenżyta poprzez analizę obrazu. Jako wykonawca projektu LIDER/24/0137/L-8/16/NCBIR/2017 (Załącznik 4: **poz. II.9.3**) skoncentrowałem się na ocenie trzech głównych wariantów nasion pszenżyta (selektywne pszenżyto, pszenżyto po przesianiu oraz plewy pszenżyta), które zostały zasiane za pomocą pneumatycznych siewników. Metoda obejmowała szybkie fotografowanie nasion za pomocą kamery oraz zastosowanie technik sztucznej inteligencji do analizy tych obrazów. Celem było opracowanie metody umożliwiającej dokładną identyfikację zanieczyszczeń w nasionach na podstawie ich cech wizualnych, wykorzystując postępy w dziedzinie analizy obrazu i technologii sieci neuronowych. Materiał badany, tj. nasiona, pozyskałem we współpracy lokalnymi gospodarstwami miasta Kórnik i Środa Wlkp. W ramach pracy jako wykonawca projektu opracowałem metodykę obejmującą detekcję krawędzi za pomocą maski Kirscha, przetwarzanie i analiza obrazów przy pomocy „PIDsystem”, segmentację, lokalizację obiektów oraz ekstrakcję parametrów geometrycznych, modeli przestrzeni barw i teksturę obrazu. Celem było identyfikowanie lokalnych nieciągłości poziomu jasności oraz konturów badanego materiału. Przygotowałem bazę danych do budowy zbiorów treningowych, walidacyjnych i testowych. Proces wykonywania modelu neuronowego opierał się na wielowarstwowych sieciach perceptronowych (MLPN) i statystycznych (uczenie maszynowe). Badanie prowadzone w ramach projektu LIDER/24/0137/L-8/16/NCBIR/2017 wykazało, że sieci neuronowe w ramach eksperymentu osiągnęły błąd klasyfikacji w zakresie od 6% do 22% względem zestawu testowego przy rozpoznawaniu typów nasion pszenżyta. Najlepszą skuteczność rozpoznawania osiągnięto przy prędkości 15 m/s dla sieci MLP 5-23-3, której wartość błędu RMS wynosiła 0,052, a współczynnik poprawności klasyfikacji wyniósł 0,99. Analiza statystyczna potwierdziła istotny wpływ zmiennej entropii na prędkość transportu nasion, co wskazuje na jej kluczową rolę w zbiorze danych. Topologia sieci MLP okazała się najbardziej efektywna w rozpoznawaniu klas nasion pszenżyta, co potwierdziły przeprowadzone eksperymenty. Wyniki tych badań opublikowałem w czasopiśmie naukowym (Załącznik 4: **poz. II. 4.36**).

W 2022 roku będąc wykonawcą projektu LIDER/24/0137/L-8/16/NCBIR/2017 (Załącznik 4: **poz. II.9.3**) przeprowadziłem analizę i ocenę próbek nasion rzepaku, jęczmienia oraz pszenicy przy użyciu stanowiska pomiarowo-badawczego, które zostało skonstruowane w

ramach projektu LIDER/24/0137/L-8/16/NCBIR/2017 przez lidera projektu. W ramach eksperymentu badałem z zespołem wpływ prędkości przepływu powietrza (ustaloną na poziomach 15, 20 oraz 25 m/s) na transport nasion. Te parametry wynikają z naszych wcześniejszych badań i doświadczeń, które zdobyłem z zespołem w trakcie realizacji zagadnień badawczych. Utworzyłem bazę danych składających się z pozyskanych obrazów od lidera projektu. To pozwoliło mi wyznaczyć 3 klasy ziarniaków na podstawie 6 wariantów badawczych, w tym sposobu ich transportu rurą oraz prędkości siewu. Następnie zaprojektowałem zbiory uczące i sieci neuronowe. Każdy wariant badawczy składał się z 3 filmów, w których wyznaczyłem 3 klasy odmian zbóż (pszenica, jęczmień, rzepak). Na pierwszym etapie badań przeprowadziłem konwersję obrazu w celu uzyskania 24-bitowego obrazu o rozdzielczości 1437 x 1253 w formacie „.jpg”. Należy dodać, że powyższa konwersja dotyczyła każdej klasy (odmiany zboża) składającej się z 212 obrazów w formacie .im7. W tym celu wykorzystałem oprogramowanie MATLAB 2021b, dostępne w ramach projektu LIDER, które umożliwiło mi konwersję obrazów z formatu „.jm7” do „.jpg”. W celu pozyskania obrazu w formacie „.jpg”, wykorzystałem dodatkowe oprogramowanie The PIVMat Toolbox for MATLAB autorstwa Frederica Moisy'ego (<https://www.mathworks.com>) oraz bibliotekę readimx-v2.1.9 (<https://www.lavision.de>). PIVMat Toolbox zawiera zestaw funkcji umożliwiających importowanie obrazów w formacie .im7. Biblioteka readimx pozwalała na efektywny odczyt danego formatu pliku za pomocą programu MATLAB. W kolejnym kroku przeprowadziłem serię przetwarzania obrazów. Kolejny etap wymagał dostosowania uzyskanych obrazów w celu wyodrębnienia z nich cech tekstury. Do analizy tekstury posłużyłem się macierzą współwystępowania poziomów pasm szarości (GLCM). W celu wykorzystania GLCM do dokładnego przedstawienia szczegółów powierzchni z teksturami proceduralnymi, konieczne było przekonwertowanie obrazu z 24-bitowej mapy do 8-bitowej głębi obrazu przy użyciu programu MATLAB oraz import danych z systemu „PIDsystem” do środowiska MATLAB. Proces tworzenia modeli neuronowych oparto na MLP w programie Statistica (uczenie maszynowe). Należy dodać, że wykorzystanie sieci MLP pozwoliło mi również na identyfikację nasion rzepaku, pszenicy i jęczmienia transportowanych rurą II z prędkością 20 ms⁻¹, dla których najniższa wartość RMS wyniosła 0,05, a współczynnik dokładności klasyfikacji 0,94. W badaniach wykorzystałem sieci MLP do nieinwazyjnego rozpoznawania ziaren pszenicy, jęczmienia i rzepaku na podstawie deskryptorów tekstury. Testy przeprowadziłem przy użyciu autorskiego stanowiska pomiarowo-badawczego, które miało na celu symulację rzeczywistych warunków procesu siewu. Przetestowałem z liderem w projekcie tylko 2 strukturalne rozwiązania transportu ziaren za pomocą rur nasienn-

powietrznych. W ramach tego zagadnienia badawczego stwierdziłem z liderem, że wzrost prędkości strumienia powietrza negatywnie wpłynął na skuteczność rozpoznawania poszczególnych klas ziaren transportowanych za pomocą rur nasienno-powietrznych, z wykorzystaniem struktur I i II. Okazuje się, że najbardziej optymalna prędkość strumienia powietrza dla ziaren transportowanych za pomocą rury (dla rozwiązania I) wynosiła 15 m/s. Wyniki tych badań opublikowałem w czasopiśmie naukowym (Załącznik 4: **poz. II.4.35**).

Użyłem nowoczesnych metod uczenia maszynowego do zautomatyzowania i usprawnienia procesu określania efektywnego wskaźnika jakości ziaren kawy. Algorytmy uczenia maszynowego mogą skutecznie rozpoznawać różne anomalie, między innymi występujące w produkcji spożywczej. Procedura przygotowania algorytmu uczenia maszynowego zależała od prawidłowego przygotowania i wstępnego przetworzenia zbioru uczącego. Zbiór ten zawierał zakodowane informacje (tj. wybrane współczynniki jakości) oparte na zdjęciach cyfrowych (dane wejściowe) i określonej klasie ziaren kawy (dane wyjściowe). Ze względu na uczenie i dostrajanie danych uzyskałem odpowiednią CNN, która charakteryzowała się wysokim współczynnikiem rozpoznawania tych ziaren kawy na poziomie 0,81 dla zestawu testowego. Analizę statystyczną przeprowadziłem na danych numerycznych w modelu przestrzeni barw RGB, co umożliwiło dokładne rozróżnienie trzech odrębnych kategorii ziaren kawy. Jednak przy użyciu przeze mnie modelu kolorów $L^*a^*b^*$ okazało się, że rozróżnienie między kategoriami jakości niedostatecznie palonych i prawidłowo palonych ziaren kawy było dużym wyzwaniem. Niemniej udało się z modelem $L^*a^*b^*$ rozróżnić kategorię nadmiernie palonych ziaren kawy. Podsumowując, analiza statystyczna przy użyciu ANOVA w przestrzeni kolorów RGB pozwoliła wyodrębnić mi trzy klasy ziaren kawy, co znacząco ułatwiło rozpoznawanie wad podczas procesu palenia. Model barw $L^*a^*b^*$ miał trudności w rozróżnianiu między niedopalonymi a właściwie dopalonymi ziarnami kawy, choć skutecznie identyfikował nadpalone ziarna. Wykorzystanie głębokich sztucznych sieci neuronowych do klasyfikacji próbek na podstawie obrazów cyfrowych o rozdzielczości 678×678 pozwoliło mi uzyskać model CNN o wysokim współczynniku dopasowania na zbiorze testowym wynoszącym 0,81. Ocena jakości kawy na podstawie cech reprezentatywnych, takich jak kolor, ma istotny wpływ dla producentów i konsumentów, zapewniając wysoki standard produktu w przemyśle palarniczym. W mojej ocenie przyszłość widziana jest przez zastosowanie metod sztucznej inteligencji do optymalizacji oceny jakości kawy, co przyczyni się do zwiększenia efektywności produkcji i minimalizacji strat, a także wzrostu sprzedaży w przemyśle spożywczej. Wyniki tych badań przedstawiłem na konferencji oraz opublikowałem w czasopiśmie naukowym (Załącznik 4: **poz. II.4.24, II.7.2.11**).

Ad. 4.3.5. Wykorzystałem nowoczesne narzędzia uczenia maszynowego oraz analizy fizyczne do oceny pektyn. W ramach pracy zaprojektowałem i przedstawiłem różne modele predykcyjne w celu oszacowania lepkości pektyn. Na podstawie analiz fizycznych wyodrębniłem z zespołem cechy produktu spożywczego, w tym: $L^*a^*b^*$ kolor, stężenie, przewodność i pH. Predykcję wyznaczyłem przy użyciu indeksu determinacji i funkcji straty dla poszczególnych algorytmów uczenia maszynowego. W wyniku przeprowadzonych prac stwierdziłem, że najskuteczniejszą metodą estymacji lepkości pektyn okazało się zastosowanie drzewa decyzyjnego ($R^2 = 0,999$) oraz lasu losowego ($R^2 = 0,998$). W przyszłości przewidywanie właściwości pektyn w zakresie rozpoznawania lepkości może być znacząco postrzegane, zwłaszcza w przemyśle spożywczym i farmaceutycznym. Przewidywanie naturalnego substratu pektynowego może przyczynić się do poprawy jakości, zwiększenia wydajności, a jednocześnie zmniejszenia strat uzyskanego produktu końcowego. Wyniki tych badań przedstawiłem na konferencji oraz opublikowałem w czasopiśmie naukowym (Załącznik 4: **poz. II.4.23, II.7.2.8-II.7.2.10**).

W powyższym opisie wybrałem te osiągnięcia badawcze spośród serii zagadnień będących w kręgu moich zainteresowań naukowych głównie ze względu na ich tematykę łączącą zagadnienia jakości produktów spożywczych z nowoczesnymi metodami ich oceny opartymi na metodach szeroko rozumianej SI. Jednocześnie o jakości podjętych badań oraz uzyskanych rezultatów świadczą publikacje o zasięgu międzynarodowym i znaczącym wskaźniku wpływu. Moje badania są szeroko cytowane w środowisku akademickim, co podkreśla ich istotny wkład w dziedzinie technologii żywności. Znaczące publikacje przyczyniły się również do rozwoju mojej kariery badawczej i umocnienia pozycji jako eksperta w mojej dziedzinie.

5. Informacja o wykazywaniu się istotną aktywnością naukową albo artystyczną realizowaną w więcej niż jednej uczelni, instytucji naukowej lub instytucji kultury, w szczególności zagranicznej.

Moje badania naukowe skupiły się na tematycznym cyklu prac, które stanowią znaczące osiągnięcie w nauce. Podczas pracy na stanowisku adiunkta w Katedrze Technologii Żywności Pochodzenia Roślinnego do 2021 roku oraz obecnie w Katedrze Mleczarstwa i Inżynierii Procesowej, prowadziłem owocną współpracę zarówno z jednostkami mojej macierzystej uczelni, jak i z innymi wiodącymi ośrodkami badawczymi, takimi jak Politechnika Poznańska, Uniwersytet im. Adama Mickiewicza w Poznaniu, Szkoła Główna Gospodarstwa Wiejskiego w Warszawie, Uniwersytet Przyrodniczy w Lublinie, Katolicki Uniwersytet Lubelski oraz

Uniwersytet Ekonomiczny w Katowicach. Ta wielowymiarowa współpraca zakończyła się licznymi publikacjami w renomowanych czasopismach z listy JCR, wzbogacającymi pole badawcze o nowe perspektywy i poglądy. To potwierdza wysoki poziom mojej działalności badawczej. Pełen wykaz materiałów konferencyjnych, rozdziałów w monografii oraz publikacji znajduje się w **załączniku 4 poz. II.2.1-II.2.17, II.4.1-4.60.**

Jedną z kluczowych, długoterminowych współprac z krajowymi i zagranicznymi jednostkami naukowymi, potwierdzoną w **załączniku 4 poz. II.11.2**, jest owocna kooperacja z SGGW w Warszawie. W ramach współpracy z SGGW w Warszawie odbyłem miesięczny staż naukowy (**Warszawa: styczeń 2021 – luty 2021**), podczas którego uczestniczyłem w badaniach struktury surowców i produktów spożywczych przy użyciu technik mikroskopii optycznej i skaningowej, w tym archiwizacja zdjęć, komputerowa analiza obrazu, interpretacja parametrów geometrycznych struktury i współczynników kształtu oraz brałem udział w badaniach oznaczenia użytkowego właściwości produktów sproszkowanych. W wyniku tych wspólnych prac opublikowałem artykuły naukowe i materiały konferencyjne (**4.4.1, 4.4.2., Załącznik 4: poz. II.2.4, II.2.8, II.7.2.15, II.7.2.19, II.7.2.21**).

Następnie, w ramach współpracy z Politechniką Poznańską przebywałem przez tydzień na wizycie (Załącznik 4: **poz. II.11.1**) zagranicznej w JK Machinery (**Czechy: 10 kwietnia 2022 -16 kwietnia 2022**), gdzie moja praca skupiała się na analizie numerycznej ruchu cząstek przy użyciu metod CFD (Dynamika Płynów Komputerowa) i DEM (Dynamika Elementów Skończonych), oraz na analizie tekstury w celu separacji zanieczyszczeń w produktach. Podczas stażu miałem okazję zapoznać się z nowoczesnymi metodami projektowania i technologii wytwarzania, w tym zastosowaniem innowacyjnych urządzeń takich jak sortowniki optyczne. Ta współpraca przyczyniła się do powstania i opublikowania artykułu (Załącznik 4: **poz. II.4.29, II.4.35**).

W ramach projektu LIDER/24/0137/L-8/16/NCBIR/2017 uczestniczyłem na wizycie zagranicznej (Załącznik 4: **poz. II.11.3**) w Farnet a.s. (**Czechy: 29 listopada – 05 grudnia 2019**), którego celem było poznanie zasad działania oraz konstrukcji systemu sterowania siewnikiem ISO-bus z czujnikami przepływu nasion. To doświadczenie zdobyte podczas wizyty zagranicznej przełożyło się na wykonanie prac w ramach projektu LIDER/24/0137/L-8/16/NCBIR/2017 oraz wykonanie publikacji naukowej (Załącznik 4: **poz. II.4.36, II.4.37, II.4.38**). Dodatkowo, osiągnięciem było jako wykonawcy projektu LIDER/24/0137/L-8/16/NCBIR/2017 zdobycie brązowego medalu na targach „Stand for Generating Low Energy Mechanical Impacts and Testing the Electrical Response of Impact Sensors” – TSIwan Innotech

Expo Invention Contest (Załącznik 4: **poz. V.4.6**) oraz pozyskania patentu (Załącznik 4: **poz. III.3.1, III.3.2**).

W ramach współpracy z Klastrem Południowej Wielkopolski przez miesiąc uczestniczyłem w stażu krajowym (Załącznik 4: **poz. II.11.4**) w przedsiębiorstwie Colian sp. z o.o. (**Kalisz: wrzesień 2017**), gdzie aktywnie uczestniczyłem w procesach technologicznych mających na celu kontrolę jakości produktów spożywczych. Moje zadania obejmowały nie tylko bezpośrednią obserwację i wsparcie w procesach produkcyjnych, ale także ocenę jakości produktów. Staż umożliwił mi zdobycie praktycznego doświadczenia w zakresie monitorowania i poprawy standardów jakościowych w przemyśle spożywczym, co przełożyło się wykonanie zadania badawczego o nr badawczym 507.752.4 finansowanego z dotacji służącej rozwojowi młodego naukowca Uniwersytetu Przyrodniczego w Poznaniu i przygotowania publikacji naukowej (Załącznik 4: **poz. II.9.4**) oraz udział w konferencji i wykonanie publikacji (Załącznik 4: **poz. II.4.47, poz. II.4.48, II.7.2.24, II.7.2.25**).

Pracowałem jako badacz w laboratorium zajmującym się sieciami neuronowymi. Moja rola skupiała się na prowadzeniu eksperymentów oraz analizie danych z wykorzystaniem modeli uczenia maszynowego. Pracując w tym środowisku, miałem okazję nie tylko rozwijać swoje umiejętności programistyczne i matematyczne, ale także zgłębiać teoretyczne podstawy sieci neuronowych oraz ich praktyczne zastosowania w Centrum Badawczo-Rozwojowym działającym w ramach przedsiębiorcy White Hill Sp. z o.o. Sp. K. W ramach prac brałem udział w opracowaniu systemu sterowania inteligentnego zarządzania oświetleniem szklarniowym bazującym na LED (**Białystok, kwiecień 2019 - czerwiec 2019**) (Załącznik 4: **poz. II.9.5**) wraz z potwierdzeniem, które znajduje się w **załączniku 7**.

Poniżej lista odbytych staży, wyjazdów zagranicznych i studyjnych, dla których potwierdzenie znajduje się w **załączniku 7**:

- JK Machinery, s.r.o - **Czechy: 10 kwietnia 2022 -16 kwietnia 2022.**
- SGGW w Warszawie - **Warszawa: styczeń 2021 – luty 2021.**
- Farnet a.s - **Czechy: 29 listopada – 05 grudnia 2019.**
- Colian sp. z o.o. - **Kalisz: wrzesień 2017.**

Moja działalność międzynarodowa obejmuje również rolę edytora w czasopiśmie Applied Sciences o zasięgu międzynarodowym, który jest dostępny na liście JCR (Załącznik 4: **poz. II.12.1, II.12.2**).

Dodatkowo, w ramach działalności międzynarodowej, pełniłem funkcję trenera w projekcie EQVEGAN, który skupiał się na analizie profili zawodowych w branży spożywczej wegańskiej (VFI) z wykorzystaniem bazy danych ESCO. Moja rola obejmowała prowadzenie szkoleń dla uczestników na poziomie EQF 6 i 7 z zakresu sztucznej inteligencji, automatyzacji i robotyki stosowanych w technologii produkcji artykułów spożywczych oraz produktów pokrewnych, opartych na czynnikach chemicznych, fizycznych i biotechnologii. Projekt EQVEGAN został wsparciem finansowym Unii Europejskiej w ramach programu Erasmus+ (Załącznik 4: **poz. II.14.1, V.5.**).

6. Informacja o osiągnięciach dydaktycznych, organizacyjnych oraz popularyzujących naukę lub sztukę.

6.1.Działalność dydaktyczna

Po uzyskaniu stopnia doktora od 2015 roku rozpocząłem pracę jako adiunkt. W ramach ustalonego planu nauczania, pełnię funkcję wykładowcy oraz prowadzę zajęcia z kilku różnych przedmiotów (Załącznik 4: **poz. V.2.1-2.13**), dostosowanych do specyfiki poszczególnych kierunków studiów i obszarów specjalizacji. Podczas prowadzenia zajęć dostarczam wykłady i ćwiczenia oparte na moich własnych materiałach. Moje zajęcia obejmują szeroki zakres tematyczny, m.in grafikę, procesy jednostkowe w kontekście przemysłu spożywczego, sztuczną inteligencję, programowanie, analizę obrazu. Dodatkowo, zajmuję się omawianiem kwestii związanych z oceną jakości i bezpieczeństwem produktów spożywczych, oraz projektowaniem wizualnym tych produktów, wykorzystując zaawansowane techniki wizualizacji (Załącznik 4: **poz. V.2.1-2.6**). Aktywnie angażuję się również jako kierownik przedmiotu Grafika inżynierska, przyczyniając się do efektywnego prowadzenia i rozwoju tego przedmiotu na kierunku Technologia Żywności i Żywnienie Człowieka od 2017 roku (Załącznik 4: **poz. V.1, V.2.4**). Prowadzę również intensywne zajęcia na Wydziale Inżynierii Środowiska i Inżynierii Mechanicznej obejmujące tematy z zakresu sztucznej inteligencji na kierunku dla Informatyków (Załącznik 4: **poz. V.2.7-2.13**). W latach 2016 - 2024 na Uniwersytecie Przyrodniczym w Poznaniu zrealizowałem zajęcia w ramach przedmiotów takich jak: Grafika inżynierska, Inżynieryjne Podstawy Procesów Produkcyjnych na kierunku Technologia Żywności i Żywnieniu Człowieka, Inżynieryjne Podstawy Procesów Produkcyjnych na kierunku Analityka Żywności. Inżynieria procesowa na kierunku Technologia Żywności i Żywnieniu Człowieka, Wstęp do procesów jednostkowych w przetwórstwie żywności, Zastosowanie inżynierii do zapewnienia jakości i bezpieczeństwa żywności na kierunku Jakość i

Bezpieczeństwo Żywności, Modelowanie neuronowe, Metody sztucznej inteligencji, Inżynieria oprogramowania, Programowanie aplikacji mobilnych, Neuronowa analiza obrazu na kierunku Informatyka stosowana. Podczas mojego zatrudnienia na stanowisku adiunkta aktywnie współpracowałem międzywydziałowo, realizując zajęcia dydaktyczne zawsze w pełnym wymiarze ustalonej normy (Załącznik 4: **poz. V.2.1-2.13**).

W 2022 roku w ramach poszerzania kompetencji w zakresie żywności wegańskiej uczestniczyłem w szkoleniach na trenera w ramach programu europejskiego tzn. projekt EQVEGAN (Załącznik 4: **poz. V.5**). Potwierdzenie znajduje się w **załączniku 7**.

W 2023 roku w ramach pogłębiania nowoczesnych rozwiązań w zakresie sztucznej inteligencji oraz poszerzania moich kompetencji zawodowych uczestniczyłem w studiach podyplomowych z zakresu Uczenie Maszynowe i Data Science na Uniwersytecie Ekonomicznym w Katowicach (Załącznik 4: **poz. V.5**) wraz z potwierdzeniem znajduje się w **załączniku 7**. Ponadto, w 2023 roku w ramach programu wsparcia dla kadry dydaktycznej „PKD - Program Podnoszenia Kompetencji Dydaktycznych Kadry Uczelni”, prowadzonego w ramach projektu „Najlepsi z natury!”, uczestniczyłem w szkoleniach takich jak: „Świadomość funkcjonowania osób z niepełnosprawnościami i ze szczególnymi potrzebami”, „Projektowanie uniwersalne – otoczenie budynków”, „Ciekawie i z sensem, czyli o sposobach na prowadzenie spotkań i dzielenie się wiedzą.” (Załącznik 4: **poz. V.5**) wraz z potwierdzeniem udziału znajduje się w **załączniku 7**.

6.2.Działalność organizacyjna

Po uzyskaniu stopnia doktora i pełnienia obowiązków dydaktycznych, od 2018 roku aktywnie zaangażowałem się w działalność w ramach komitetu organizacyjnego i technicznego, odgrywając kluczową rolę w organizacji V Międzynarodowej Konferencji „Meat in Technology and Human Nutrition” (Załącznik 4: **poz. II.7.4**). W ramach mojego zaangażowania zaprojektowałem i wdrożyłem zaawansowany system informatyczny oparty na języku PHP, obsługujący rejestrację uczestników oraz przesyłanie abstraktów. Pełniłem również rolę administratora, zarządzając przychodzącymi wiadomościami od uczestników i zapewniając płynność komunikacji. Moja rola nie ograniczała się jedynie do aspektów technicznych. Aktywnie wspierałem przygotowania do konferencji, dbając o organizacyjne detale wszystkich sesji oraz biorąc udział jako prelegent (Załącznik 4: **poz. II.7.2.24, II.7.2.25**). Znacząco przyczyniłem się do sukcesu wydarzenia, pozyskując sponsora wspierającego organizację konferencji. To aktywność na rzecz konferencji przyczyniła się także, że od 2018 roku zacząłem pełnić rolę zajmując się obsługą strony internetowej wydziału

(<https://wnoziz.up.poznan.pl>) (Załącznik 4: **poz. V.6**). Jako projektant grafik wektorowych i rastrowych, odpowiadam nie tylko za estetyczne projektowanie materiałów wizualnych, ale także za ich strategiczne dopasowanie do celów wydziału. Moje prace graficzne pomagają w efektywnej komunikacji z odbiorcami. Jako 2-gi administrator strony internetowej dbam nie tylko o techniczne aspekty naszej obecności on-line, ale również o zapewnienie, żeby strona była wizytówką wydziału, odzwierciedlającą jego misję i wartości. Jako redaktor strony wydziału mam istotny udział w tworzeniu treści, które nie tylko były atrakcyjne, ale także merytorycznie bogate i odpowiadały potrzebom naszych odbiorców. Współpracowałem z zespołem władz dziekańskich, aby opracowywać artykuły, raporty, wpisy na bloga oraz inne treści, które wspierały cele wydziału w zakresie edukacji, badań i promocji.

W latach 2019-2020 w ramach International Conference on Digital Image Processing brałem udział jako członek Komitetu Technicznego (Załącznik 4: **poz. II.7.2, II.7.3**). Moja rola nie ograniczała się tylko do udziału w komitecie, ale również obejmowała aktywne recenzowanie artykułów naukowych przed ich prezentacją na konferencji (Załącznik 4: **poz. II.13.22, II.13.23**). Dzięki mojemu zaangażowaniu w proces recenzji mogłem wnieść istotny wkład w zapewnienie wysokiego poziomu merytorycznego prezentowanych prac.

W ramach działalności na rzecz Uniwersytetu Przyrodniczego w Poznaniu, byłem także zaangażowany w szereg inicjatyw, które miały istotny wpływ na organizacyjne aspekty mojej pracy (Załącznik 4: **poz. V.6.1-6.11**). Moje zadania obejmowały m.in. pełnienie funkcji członka w komisjach oraz zespołach takich jak: komisja ds. utworzenia nowego kierunku na Wydział Nauk o Żywności i Żywieniu „Projektowanie żywności” od 2023 roku (Załącznik 4: **poz. V.6.1**), komisja ds. Internetowej Promocji Wydziału od 2022 roku (Załącznik 4: **poz. V.6.3**), zespół Uniwersytetu Przyrodniczego bez barier cyfrowych od 2022 roku (Załącznik 4: **poz. V.6.4**), zespół UP sukcesywnej dostawy licencji i oprogramowania Microsoft w 2022 roku (Załącznik 4: **poz. V.6.5**), zespół ds. pozyskiwania środków na rozbudowę infrastruktury Wydziału w 2016 roku (Załącznik 4: **poz. V.6.11**). Potwierdzenie inicjatyw na rzecz działań organizacyjnych znajduje się w **załączniku 7**.

W 2022 roku powołano mnie przez Dziekana Wydziału do koordynowania obchodów 60-lecia Wydziału (Załącznik 4: **poz. V.6.6**). W 2023 roku powołano mnie przez Dyrektora Biblioteki UPP do koordynowania 70-lecia Biblioteki (Załącznik 4: **poz. V.6.2**). Od 2021 roku powołano mnie przez władze dziekańskie do pełnienia roli opiekuna sali komputerowej wydziału (Załącznik 4: **poz. V.6.8**).

W latach 2016-2022 byłem członkiem Stowarzyszenia bibliotekarzy Polski – oddział w Poznaniu m.in. w ramach tego działania utworzyłem stronę internetową (Załącznik 4: **poz.**

II.9.3). Od 2021 roku jestem członkiem Polskiego Towarzystwa Technologów Żywności Oddział Wielkopolski (PTTŻ-OW) (Załącznik 4: **poz. II.10.2**). Od 2023 roku jestem członkiem Polskiej grupy badawczej systemów uczących się (<http://www.sigml.pl>) (Załącznik 4: **poz. II.10.1**). Potwierdzenie członkostwa znajduje się w **załączniku 7**.

Otrzymałem kilka wyróżnień i nagród za moje zaangażowanie na rzecz organizacji na Uniwersytecie Przyrodniczym w Poznaniu (Załącznik 4: **poz. V.4.1-4.9**). Po doktoracie otrzymałem w 2016 oraz w 2018 roku nagrodę zespołową za osiągnięcia zawodowe przez JM Rektora. W 2021 roku zostałem wyróżniony przez JM Rektora za sprawowanie nadzoru nad modernizacją sal laboratoryjnych Wydziału (Załącznik 4: **poz. V.4.5**). W 2022 roku, otrzymałem nagrodę zespołową II stopnia za działania związane z zarządzaniem stroną internetową, w tym dostosowanie informacji dla osób z niepełnosprawnością (Załącznik 4: **poz. V.4.4**). W 2023 roku otrzymałem wyróżnienie od JM Rektora za moje działania promocyjne i obsługę strony internetowej oraz mediów społecznościowych Wydziału (Załącznik 4: **poz. V.4.3**). Te wyróżnienia są dla mnie wyrazem uznania za wysiłek włożony w rozwój i wsparcie uniwersyteckiej społeczności. Potwierdzenie otrzymania nagród i wyróżnień znajdują się w **załączniku 7**.

6.3.Działalność popularyzująca naukę

Moja praca związana z popularyzacją nauki polega na organizowaniu wykładów i warsztatów dla uczniów szkół podstawowych, średnich oraz dorosłych. Otrzymałem podziękowania za zorganizowanie różnego typu wydarzeń (Załącznik 4: **poz. II.7.1.1-7.1.11**) m.in. przygotowałem pre-event z okazji Nocy Naukowców na Wydziale (Poznań, 11 czerwca 2024), przeprowadziłem także dla zaproszonych gości ze szkoły podstawowej warsztaty pt. „Zabawy ze sztuczną inteligencją”, a w ramach popularyzacji nauki dla zaproszonych uczniów z Marszewa pt. „Zastosowanie grafiki komputerowej, programowania, analizy obrazu, sztucznej inteligencji w żywności” (Poznań, marzec 2022). Natomiast na zaproszenie szkół udałem się do nich by przedstawić wykład promujący Wydział pod hasłem: „Sztuczna inteligencja wokół nas”, (Rokietnica, 12 czerwca 2024), (Leszno, 9 kwietnia 2024), (Powiercie 19 marca 2024), a także przybliżyłem uczniom rolę sztucznej inteligencji wokół naszego otoczenia (Kiekrz, 11 kwietnia 2024). W ramach XXVII Poznańskiego Festiwalu Nauki i Sztuki przygotowałem merytoryczne i przeprowadziłem wydarzenia pt. „Sztuczna inteligencja (SI) - zagrożenia, perspektywy” oraz „Jak sztuczna inteligencja interpretuje obrazy żywności?” (Poznań, 16 kwietnia 2024). Wygłosiłem również wykład pt. Rola sztucznej inteligencji w analizie żywności na Targach LABS EXPO, uświadamiając społeczność jak analiza żywności

może skutecznie współpracować ze sztuczną inteligencją (Poznań, 20 marca 2024). Podczas dni otwartych na Wydziale podzieliłem się z zainteresowanymi wiedzą „Jak sztuczna inteligencja interpretuje obrazy żywności?” (Poznań, 25 stycznia 2023), z kolei wykład pt.: „Sztuczna inteligencja w rolnictwie” zaprezentowałem na IV Krajowych Dni Pola (Sielinko, 3-5 czerwca 2023). Czynnie uczestniczyłem w spotkaniu promującym Tydzień Bibliotek pt. „Chleba naszego powszedniego”, przedstawiając wykład zatytułowany „Sztuczna inteligencja przy ocenie stanu jakościowego produktów rolno-spożywczych” (Poznań, 13 maja 2022). Przeprowadziłem również wykład „Zastosowanie metod sztucznej inteligencji w branży rolno-spożywczej” dla Polskiego Towarzystwa Technologów Żywności Oddział Wielkopolski (Poznań, 8 listopada 2022). Podziękowania będące potwierdzeniem podjętych przedsięwzięć zamieściłem w **załączniku 7**.

7. Oprócz kwestii wymienionych w pkt. 1-6, wnioskodawca może podać inne informacje, ważne z jego punktu widzenia, dotyczące jego kariery zawodowej.

W 2022 roku zainicjowałem działania badawcze z wykorzystaniem uczenia maszynowego, które przedstawiłem na konferencji, obejmujące prognozowanie jakości burraty (Załącznik 4: **poz. II.7.2.12**), ocenę stopnia związania wody w zależności od przebiegu fermentacji mleka (Załącznik 4: **poz. II.7.2.13**) oraz analizę tekstury w celu identyfikacji drożdży fermentujących i niefermentujących laktozę w kefirze (Załącznik 4: **poz. II.7.2.14**). W efekcie moje działania badawcze dostrzeżono i od października 2023 roku prowadzę wspólne badania jako wykonawca projektu nr 506-026 pt. „Sieć badawcza uczelni przyrodniczych na rzecz rozwoju polskiego sektora mleczarstwa”. Jej główne cele to innowacyjne działania badawcze oraz wdrażanie nowoczesnych technologii, które mają zwiększyć efektywność produkcji, poprawić jakość produktów oraz wspierać zrównoważony rozwój branży mleczarskiej w Polsce (Załącznik 4: **poz. II.9.1**).

Dotychczasowa aktywność związana z grantami obejmuje także zarządzanie działaniem badawczym w ramach programu MINIATURA DEC-2021/05/X/NZ9/01014/2 w Narodowym Centrum Nauki (NCN) pt. Analiza wpływu morfologii mikrocząstek na stan jakościowy suszonych rozpyłowo owoców z zastosowaniem uczenia maszynowego i głębokiego (**czerwiec 2022 - czerwiec 2023**) (Załącznik 4: **poz. II.9.2**).

W 2023 roku także otrzymałem wyróżnienie od JM Rektora za moje osiągnięcia naukowe, szczególnie za wysoką jakość moich osiągnięć publikacyjnych. To wyróżnienie jest dla mnie niezwykle ważne, ponieważ docenia moją pracę badawczą oraz wkład w rozwój naukowy na

rzecz uczelni. Jest to także inspiracja do dalszej pracy i podnoszenia jakości moich osiągnięć naukowych (Załącznik 4: **poz. V.4.2**) wraz z potwierdzeniem znajduje się w **załączniku 7**.

W ramach współpracy z 22 uznanymi wydawnictwami naukowymi, miałem okazję przeprowadzić 56 szczegółowych recenzji prac naukowych (Załącznik 4: **poz. II.13.1-13.23**).

Przed uzyskaniem stopnia doktora (2011-2015) wziąłem udział w 6 konferencjach naukowych (Załącznik 4: **poz. II.7.2.1-7.2.6**). Po uzyskaniu doktoratu (od 2015 do 2024) uczestniczyłem w 9 konferencjach (Załącznik 4: **poz. II.7.2.7-7.2.28**). W ramach konferencji naukowych, w tym międzynarodowych i krajowych, miałem okazję zaprezentować swoje umiejętności, osiągnięcia, wyniki, metody, teoretyczne podstawy oraz wnioski płynące z badań w formie referatów, posterów i szkoleń (Załącznik 4: **poz. II.7.2.1-7.2.28, II.7.3.1-7.3.5**).

Moja aktywność naukowa osiągnęła znaczący poziom, czego dowodem jest to, że **całkowity dorobek naukowy** (na dzień 10 lipca 2024r) według aktualnej punktacji Ministerstwa Nauki i Szkolnictwa Wyższego (MNiSW)/ Ministerstwa Edukacji i Nauki (MEiN) wynosi **3574 punktów, w tym 600 punktów obejmuje punktacja za publikacje stanowiące podstawę wniosku habilitacyjnego**. Prace, które opublikowałem, uzyskały **sumaryczny Impact Factor** wynoszący **89,261**, (w tym **19,578** za publikacje stanowiące podstawę wniosku habilitacyjnego), co potwierdza wysoką jakość moich osiągnięć publikacyjnych. Dodatkowo, zajmuję 68. i 98. pozycję w rankingu TOP 500 autorów Uniwersytetu Przyrodniczego w Poznaniu (scival.com) odpowiednio na podstawie wskaźnika h-index i Impact Factor w latach 2014-2023 (stan na 5 lipca 2024r), co świadczy o uznaniu moich publikacji przez międzynarodową społeczność naukową. Te wyniki są potwierdzeniem mojego zaangażowania w badania oraz ciągłego dążenia do osiągania wysokiej jakości i wpływu mojej pracy naukowej (Załącznik 4: **poz. IV.1-4**).

W Tabeli 1 przedstawione zostało zestawienie dorobku naukowego z podziałem na podstawowe formy aktywności naukowej, w którym uwzględniłem ocenę punktową czasopism wg MNiSW/MEiN, zgodną z rokiem wydania publikacji oraz IF za rok wydania. Analiza ta umożliwia ocenę jakości i znaczenia publikacji na podstawie punktacji i wpływu czasopism, w których się ukazały.

Tabela 2 prezentuje dorobek naukowy mierzone przez liczbę cytowań w bazach Web of Science i Scopus. Porównanie to pozwala ocenić zasięg i wpływ prac naukowych w dwóch kluczowych bazach danych naukowo metrycznych.

Tabela 1. Zestawienie dorobku publikacyjnego przed i po uzyskaniu stopnia doktora.

Rodzaj pracy	Po uzyskaniu stopnia doktora:			Przed uzyskaniem stopnia doktora:			Całkowity:		
	Liczba poz.	Liczba punktów MEN/MNiSW	IF	Liczba poz.	Liczba punktów w MEN/MNiSW	IF	Liczba poz.	Liczba punktów w MEN/MNiSW	IF
1. Oryginalne opublikowane prace twórcze									
1.1. Publikacje w czasopismach naukowych posiadających współczynnik IF	27	2730	89,261	0	0	0	27	2730	89,261
1.2. Wykaz pozostałych opublikowanych artykułów w czasopismach naukowych nieposiadających współczynnika IF	4	48	-	7	32	-	11	80	
1.3. Pełnotekstowe prace konferencyjne	12	120	-	15	190	-	23	310	-
1.4. Rozdziały w monografii naukowej	16	400	-	1	4	-	21	404	-
1.5. Patenty, zgłoszenia patentowe	2	50		0			2	50	
Łącznie	61	3348	89,261	23	226	0	84	3574	89,261

Tabela 2. Zestawienie dorobku naukowego wg cytowania w Web of Science i Scopus z dn. 5 lipca 2024r.

Baza	Liczba publikacji	Liczba cytowań	Liczba cytowań bez autocytowań	Index Hirscha
Web of Science	65	669	324	17
Scopus	70	782	181	18

W celu poszerzenia mojej wiedzy i umiejętności w dziedzinie technik i nowoczesnych metod badawczych, a także praktycznego zastosowania uzyskanych wyników badań, uczestniczyłem po doktoracie **w studiach podyplomowych** oraz w wielu kursach, szkoleniach i webinarach, takich jak (Załącznik 4: **poz. V.5**):

- 29/07/2024 - szkolenie - Data Science: Analiza danych w Python i PANDAS.
- 10/03/2024 - szkolenie - Explainable AI (XAI) with Python.
- 07/12/2023 - szkolenie - Deep Learning w języku Python - Konwolucyjne Sieci Neuronowe.
- 05/12/2023-06/12/2023 - szkolenie „Świadomość funkcjonowania osób z niepełno-sprawnościami i ze szczególnymi potrzebami”.
- 25/11/2023 - kurs Midjourney & ChatGPT - sztuczna inteligencja w projektowaniu graficznym.
- 23/11/2023-24/11/2023 - szkolenie projektowanie uniwersalne – otoczenie budynków.
- 22/08/2023 - szkolenie - Nowy interfejs użytkownika EBSCO Discovery Service - przeszukiwanie zasobów naukowych jeszcze nigdy nie było tak proste.
- 16/08/2023 - szkolenie - Akademicki startup – czy to jest możliwe? W ramach projektu "Deep Tech Creativity", Akronim: Detect!
- 07/08/2023 – szkolenie: uczenie maszynowe w Pythonie. Podstawy, perceptron, regresja.

- 13/07/2023- 14/07/2023 - szkolenie w ramach projektu „Doskonałość Dydaktyczna Uczelni” pt. Ciekawie i z sensem, czyli o sposobach na prowadzenie spotkań i dzielenie się wiedzą.
- 20/06/2023 - szkolenie - przekształć katalog Twojej instytucji dzięki BiblioGraph – EBSCO.
- 09/06/2023 - szkolenie - How to select a journal and how to submit correctly – Springer Nature.
- 18/05/2023 - szkolenie dla wnioskodawców NCN: Rozliczanie projektów – raporty końcowe.
- 17/05/2023-23/04/2023 - kurs z machine learning przy użyciu chmur obliczeniowych - AWS Academy Machine Learning Foundations.
- 15/03/2023 - Twój profil autora w bazie Scopus.
- 14/03/2023 - szkolenie z danych badawczych jako istotny element komunikacji naukowej zrealizowane przez Elsevier.
- 28/02/2023 - szkolenie z literatury naukowej na platformie ScienceDirect - nie tylko PDF zrealizowane przez Elsevier.
- 2023 - specjalizacja w zakresie metod sztucznej inteligencji i analizy danych, **ukończone studia podyplomowe pt. uczenie maszynowe i data science**, Uniwersytet Ekonomiczny w Katowicach (z wynikiem egzaminu dyplomowego: 4.5).
- 10/2022-12/2022 - szkolenie na trenera w ramach realizowanego projektu EQVEGAN: Train the Trainer module “Green Skills”.
- 10/2022-12/2022 - szkolenie na trenera w ramach realizowanego projektu EQVEGAN: Train the Trainer module “Soft Skills”.
- 10/2022-12/2022 - szkolenie na trenera w ramach realizowanego projektu EQVEGAN: Train the Trainer module “Plant based Processing”.
- 10/2022-12/2022 - szkolenie na trenera w ramach realizowanego projektu EQVEGAN: Train the Trainer module “Digitalization and Automation”.
- 24/11/2022-02/12/2022 - szkolenie z „Przepisów prawa żywnościowego w kontekście komercjalizacji wyników badań naukowych i wdrażania nowych produktów spożywczych na rynek” – IGI FOOD LAW Sp. z o. o.
- 21/11/2022-22/11/2022 - szkolenie z sieci neuronowych zrealizowane przez StatSoft Polska.
- 26/10/2022 - szkolenie z celu zrównoważonego rozwoju (SDG) - jak w prosty sposób można ukazać wkład w potrzeby społeczeństwa zrealizowane przez Elsevier.
- 24/10/2022 - szkolenie z uczenia maszynowego – drzewa decyzyjne i lasy losowe – Python.
- 15/06/2022 - szkolenie Scopus: jak zwiększyć szansę czasopisma na indeksację w bazie? - zrealizowane przez Elsevier
- 10/06/2021 - szkolenie z Android od podstaw – tworzenie aplikacji.
- 31/05/2021 - szkolenie z Room w Android.
- 02/03/2021 - szkolenie - Android - z kompletnego zera do zaangażowanego developera.
- 14/01/2020-17/01/2020 - szkolenie w zakresie suszenia rozpyłowego w przedsiębiorstwie Paula Ingredients Sp. z o.o. Sp. k.
- 12/01/2020-15/01/2020 - szkolenie z Deep Learning A-Z: Hands-On Artificial Neural Networks.
- 07/01/2020-08/01/2020 - szkolenie z Tensorflow for Deep Learning with Python.

Potwierdzenia kopii dokumentów odbycia kursów i szkoleń znajdują się w **Załączniku 7** do wniosku o wszczęcie postępowania habilitacyjnego.