

12

Zastosowanie spektroskopii, uczenia maszynowego oraz teledetekcji w ochronie regionalnych produktów żywnościowych

ROBERT DULIŃSKI

Katedra Biotechnologii i Ogólnej Technologii Żywności,
Wydział Technologii Żywności, Uniwersytet Rolniczy w Krakowie,
ul. Balicka 122, 30-149 Kraków

robert.dulinski@urk.edu.pl, <https://orcid.org/0000-0002-0370-2556>

Streszczenie: Jakość i autentyczność produktów żywnościowych stają się coraz ważniejsze dla konsumentów na całym świecie. Metody oparte na fotonice, takie jak spektroskopia w zakresie bliskiej i dalekiej podczerwieni czy spektrometria mas, stanowią punkt wyjścia do opracowania zintegrowanych systemów monitorowania autentyczności żywności. W pracy skupiono się na pokazaniu, jak techniki spektroskopowe, algorytmy uczenia maszynowego i metody teledetekcyjne mogą wspomagać ochronę regionalnych produktów spożywczych oraz monitorowanie upraw o określonym pochodzeniu geograficznym. Podkreślono aspekty zastosowania tych technik w praktyce, a także potencjał ich aplikacji w przyszłości w kontekście rosnącego nacisku na zrównoważoną produkcję żywności i ochronę specyficznych regionów oraz pochodzących z nich wyrobów.

Słowa kluczowe: techniki spektroskopowe, uczenie maszynowe, regionalne produkty żywnościowe, pochodzenie geograficzne upraw

1. Wstęp

Ciągłe zmiany klimatyczne, postępująca globalizacja oraz rosnące oczekiwania konsumentów skierowały uwagę naukowców na problem ochrony jakości oraz autentyczności regionalnych produktów spożywczych (Grunert i Aachmann, 2016). W ostatnich latach podstawowe techniki analityczne, takie jak spektroskopia, wspomagane przez uczenie maszynowe oraz metody teledetekcyjne zyskały na popularności jako narzędzia pozwalające na precyzyjne monitorowanie upraw, a także identyfikację i autentyfikację produktów żywnościowych (González-Domínguez, 2022; Feng i in., 2021).

Celem tego studium jest ukazanie, jak innowacje technologiczne mogą służyć ochronie i promocji unikatowych artykułów i wyrobów spożywczych, jednocześnie wspierając zrównoważone rolnictwo i ochronę środowiska.

2. Techniki spektroskopowe

Techniki spektroskopowe, które obejmują takie metody jak spektroskopia w podczerwieni (IR), spektroskopia bliskiej podczerwieni (NIR), spektroskopia Ramana i spektroskopia mas (MS), są stosowane do identyfikacji i kwantyfikacji składników chemicznych w próbkach żywności i roślin (Taylan i in., 2021; Huang i in., 2020). Wykorzystują one fakt, że różne związki chemiczne pochłaniają lub emitują światło o określonych długościach fal, co pozwala na identyfikację tych substancji na podstawie ich unikalnych „sygnatur” spektroskopowych (Didham i in., 2020).

Obecnie autentyczność wielu produktów udaje się potwierdzić na podstawie identyfikacji i analizy ilościowej określonych związków organicznych, tzw. markerów molekularnych, przy użyciu nowoczesnych metod analitycznych. Jako markery najczęściej stosowane są DNA, białka/peptydy, małe związki smakowe i zapachowe, ale też węglowodany czy związki o charakterze lipidowym (Cubero-Leon i in., 2014).

W ostatnich latach ukazało się wiele prac poświęconych identyfikowaniu markerów autentyczności przy użyciu zaawansowanych, sprzężonych technik, takich jak chromatografia gazowa lub cieczowa ze spektrometrią mas (GC-MS, LC-MS), spektrometria mas w warunkach otoczenia (ang. *ambient* DESI-MS, LESA-MS) czy oparta na monitorowaniu DNA reakcja łańcuchowa polimerazy (PCR) (Montowska i in., 2015; Danezis i in., 2016).

Do interpretacji tzw. surowych danych pochodzących z rejestracji widm spektroskopowych zazwyczaj korzysta się z rozwiązań oferowanych przez chemometrię – dziedzinę chemii zajmującą się analizą danych chemicznych i ekstrakcją informacji na ich podstawie (Cubero-Leon i in., 2014; Chakravartula i in., 2022).

Algorytmy uczenia maszynowego, takie jak sieci neuronowe, maszyny wektorów nośnych (SVM) czy algorytmy oparte na drzewach decyzyjnych, mogą być używane

do wspomaganiania analizy i interpretacji danych spektroskopowych (Chakravartula i in., 2022). Algorytmy te są w stanie rozpoznawać w danych wzorce i zależności, które mogą być trudne do wykrycia przez tradycyjne metody statystyczne. Dzięki temu mogą one przewidywać pochodzenie geograficzne produktów żywnościowych lub stan roślin na podstawie danych spektroskopowych. Każda z powyższych technik ma zalety, ale również pewne ograniczenia, szczególnie w przypadku badań produktów złożonych i przetworzonych, w których analizowane związki ulegają denaturacji i degradacji.

Tabela 1. Porównanie modeli analizy pochodzenia geograficznego oraz botanicznego wybranych produktów żywnościowych

Cel	Miód	Oliwa	Wino
Pochodzenie geograficzne	Analiza stabilnych izotopów Zawartość minerałów Składniki śladowe	Analiza stabilnych izotopów Komponenty śladowe	Analiza stabilnych izotopów Zawartość minerałów Składniki śladowe
Pochodzenie botaniczne	Analiza pyłku (mikroskopia) Analiza minerałów Analiza DNA	Analiza profilu trójglicerydów Analiza składu kwasów tłuszczowych Zawartość tokoferoli	Kwas szikimowy (wina burgundzkie) Wzorec antocyjanów (wina czerwone)
Zafałszowanie oraz denominacja produktu	Analiza stabilnych izotopów Oznaczanie sacharydów Analiza pyłku (mikroskopia)	Analiza profilu trójglicerydów Analiza składu kwasów tłuszczowych Zawartość tokoferoli Zawartość stigmastadienu	Analiza stabilnych izotopów Zawartość minerałów Analiza związków lotnych

Źródło: opracowanie własne na podstawie: Didham i in., 2020; Green i in., 2020; Danezis i in., 2016; Targoński i Stój, 2005; Ciulu i in., 2021; Hencz i in., 2022; Revelou i in., 2021

3. Algorytmy uczenia maszynowego

Uczenie maszynowe, gałąź sztucznej inteligencji, wykorzystuje algorytmy i modele statystyczne, które pozwalają systemom komputerowym na poprawę wydajności bez konieczności bezpośredniego programowania (Qin, 2020). Taki system „uczy się” z doświadczenia, co oznacza, że jest zdolny do samodzielnego dostosowywania swoich parametrów na podstawie analizy danych wejściowych. Pierwotnie algorytmy uczenia maszynowego zysały dużą popularność w takich dziedzinach jak bankowość, ubezpieczenia czy cyberbezpieczeństwo (Leo i in., 2019), a w ostatnim

czasie ich aplikacje poszerzają się o kolejne pola, m.in. związane z agronomią oraz analizą autentyczności żywności i jej pochodzenia (Chakravartula i in., 2022).

Algorytmy uczenia maszynowego są stosowane w ochronie produktów żywnościowych w celu ich identyfikacji i klasyfikacji na podstawie charakterystycznych cech. Mogą one być użyte na przykład do identyfikacji wyrobów o określonym pochodzeniu geograficznym, takich jak wina, sery czy alkohole (Fuentes i in., 2020; Haque i in., 2018), na podstawie ich unikalnych cech spektroskopowych. Algorytmy mogą być trenowane na danych z różnych źródeł, takich jak obrazy satelitarne, dane spektroskopowe czy genetyczne, co pozwala na ich efektywne wykorzystanie w różnych kontekstach (Chakravartula i in., 2022).

Metoda ta wykorzystywana jest również w monitorowaniu upraw roślin. Przy użyciu technik teledetekcyjnych, takich jak analiza obrazów satelitarnych, algorytmy uczenia maszynowego mogą identyfikować różne typy upraw, oceniać ich stan zdrowia, a także przewidywać plony (Mastilović i in., 2023). Umożliwiają w ten sposób skuteczne zarządzanie zasobami rolnymi i optymalizację procesów uprawy (Török i in., 2020).

Zastosowanie algorytmów uczenia maszynowego w ochronie produktów żywnościowych i monitorowaniu upraw roślin jest obszarem o dużym potencjale rozwoju. W miarę jak technologia ta staje się coraz bardziej zaawansowana, możliwe jest jej wykorzystanie do stawiania czoła wielu wyzwaniom, z którymi mamy do czynienia w dzisiejszym rolnictwie. Algorytmy te mogą więc zostać użyte do poprawy efektywności produkcji żywności, ochrony unikatowych wyrobów regionalnych czy zarządzania „wegetacją” w okresach suszy (Fuentes i in., 2020).

4. Metody teledetekcyjne

Nowoczesne metody teledetekcyjne, takie jak satelitarne systemy obserwacji Ziemi (GPS i GIS), mogą dostarczać obejmujących szeroki zakres i systematycznych danych o roślinności na dużych obszarach (Stombaugh, 2018). Na przykład analiza obrazów multispektralnych lub hyperspektralnych pozwala wykrywać subtelne zmiany w spektrum odbitego światła, wskazujące na różnice w gatunkach roślin, ich stan zdrowia, poziom nawodnienia czy nawet konkretny typ gleby, na której rosną (Yoon i Lee, 2022; González-Domínguez, 2022).

Stosowanie tych technologii pozwala na skuteczne monitorowanie i ochronę regionalnych produktów żywnościowych oraz upraw roślin o określonym pochodzeniu geograficznym. Może pomóc chociażby w wykrywaniu fałszywych wyrobów, które są sprzedawane jako „regionalne” lub „tradycyjne”, mimo że nie spełniają wymogów dotyczących ich pochodzenia czy sposobu produkcji. Ponadto wspomaga obserwację stanu zdrowia roślin i określanie ewentualnych problemów, takich jak choroby czy stres spowodowany suszą.

4.1. Definicja i zastosowanie metod teledetekcyjnych

Teledetekcja to nauka i technika pomiaru, analizy i interpretacji właściwości obiektów, obszarów lub zjawisk przez zdalne badanie promieniowania elektromagnetycznego zarejestrowanego przez sensory na satelitach lub statkach powietrznych (Cisternas i in., 2020). W kontekście ochrony regionalnych produktów żywnościowych i monitoringu upraw roślin o określonym pochodzeniu geograficznym teledetekcja oferuje możliwość obserwacji i analizy na dużą skalę, zapewniając dane o stanie zdrowia roślin, stopniu nawodnienia, składzie gleby i innych kluczowych parametrach (Garrido i Caranqui, 2020).

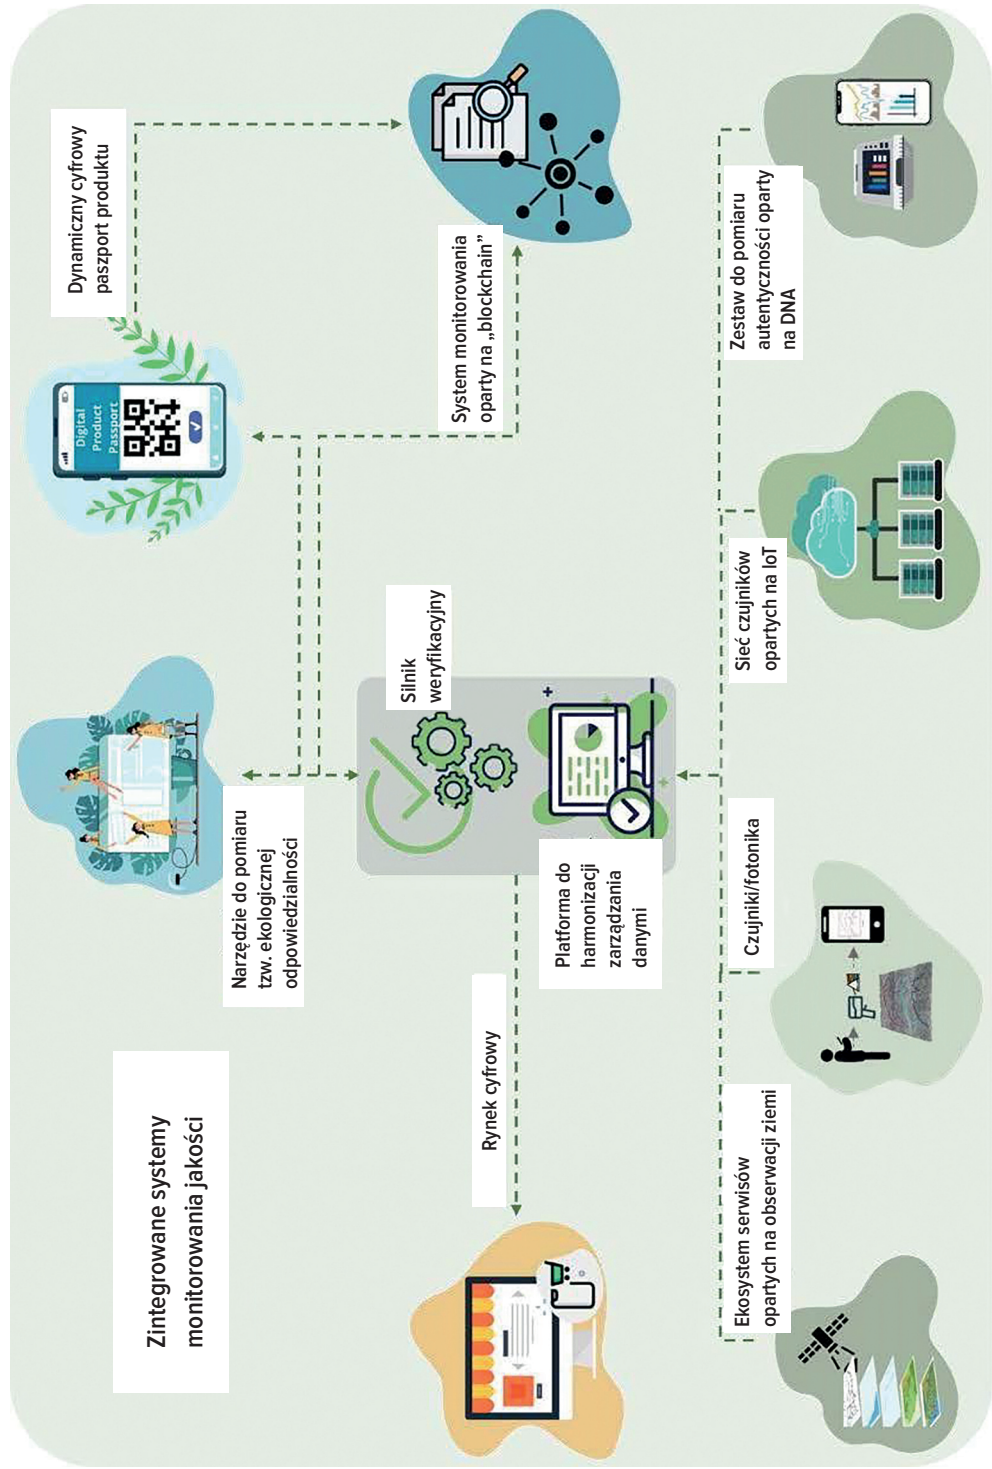
4.2. Techniki teledetekcyjne w monitorowaniu upraw

Istnieje kilka technik teledetekcyjnych, które mogą być wykorzystywane do obserwacji upraw. Przykłady stanowią obrazy z multispektralnych sensorów satelitarnych, które pozwalają uzyskać informacje o stanie zdrowia roślin, i radarów interferometrycznych (InSAR), które dostarczają danych o deformacjach powierzchni ziemi (Feng i in., 2021).

Opracowano też bardziej zaawansowane systemy zbierania danych teledetekcyjnych, oferujące analizę kluczowych komponentów gleby, składu chemicznego czy pierwiastków, które mogą znaleźć przełożenie we wspomnianych wcześniej sygnaturach poszczególnych upraw regionalnych na glebach o określonej charakterystyce i dalej w składzie produktów żywnościowych przygotowanych na bazie tych upraw (nasiona, liście, komponenty pasz, produkty pochodzenia zwierzęcego) (Elmasry i in., 2012; Garrido i Caranqui, 2020; de Sousa i in., 2023).

Najnowsze rozwinięcia w metodach teledetekcyjnych obejmują korzystanie z technologii hyperspektralnej, która pozwala na bardzo szczegółową analizę odbicia światła przez rośliny, a tym samym na wysoce precyzyjną identyfikację stanu ich zdrowia. Inne nowoczesne rozwiązanie stanowi wykorzystanie dronów do zbierania danych (Feng i in., 2021).

Na rycinie 1 zaprezentowano schemat zintegrowanego systemu do monitorowania autentyczności produktów regionalnych, który opiera się na zbieraniu danych pochodzących z ekosystemów obserwacji Ziemi, pomiarów spektroskopowych, sieci czujników tzw. Internetu rzeczy (*Internet of things*, IoT) oraz biosensorów. Odnotowujemy tendencję do miniaturyzacji urządzeń służących do tych badań, o czym świadczą np. małe nabiurkowe spektrometry, tablety, miniaturowe aparaty do PCR, które mogą zastosować w warunkach polowych nie zawsze doskonale przeszkoleni użytkownicy. Szczególnie w tym pierwszym przypadku może to być po prostu producent, dostawca. Nawet dostęp do danych telemetrycznych często oferowany jest już nie tylko przez agendy rządowe (NASA), ale też prywatne firmy, które wynoszą na orbitę małe satelity wykonujące zdjęcia planety. W kolejnym kroku uzyskane



Ryc. 1. Przykład zintegrowanego systemu do oceny autentyczności upraw i regionalnych produktów żywnościowych

Źródło: opracowanie własne na podstawie: Török i in., 2020; Ciulu i in., 2021; Revelou i in., 2021

dane są integrowane przez wspomniane wcześniej narzędzia powiązane z uczeniem maszynowym, sztucznymi sieciami neuronowymi. Na ostatnim etapie algorytmy przyporządkowują i klasyfikują produkt, co umożliwia producentom nadanie mu specjalnego identyfikatora czy cyfrowego paszportu.

Poszerzeniem pola wykorzystania zintegrowanych systemów monitorowania jakości może być zastosowanie narzędzia do pomiaru ekologicznej odpowiedzialności powiązane ze stopniem autentyfikacji, przetworzenia i z geograficznym pochodzeniem produktu.

5. Wybrane przykłady produktów regionalnych i metod potwierdzania ich autentyczności

5.1. Produkty regionalne w Unii Europejskiej

Inicjatorami stworzenia przepisów ochraniających regionalne specjały byli Francuzi. Przekształcili oni swoje narodowe prawo, które powstało już w latach 30. XX w. i pierwotnie dotyczyło ochrony win, w system obowiązujący na poziomie europejskim. Regulacje te przyspieszyły rozwój produkcji regionalnych i popularyzację tradycyjnych wyrobów oraz pomogły realizować cele reformy wspólnej polityki rolnej, która dążyła do podniesienia jakości i jednocześnie zmniejszenia ilości żywności wytwarzanej w Europie.

Wyróżnienie „regionalnymi oznaczeniami” zwiększa konkurencyjność towarów i może być ważnym czynnikiem wpływającym na decyzje potencjalnych klientów (Török i in., 2020). Produkt, którego pochodzenie jest gwarantowane przez Unię Europejską, przyczynia się do tworzenia wizerunku obszaru, z którego pochodzi, i tym samym promuje odwiedzanie tego regionu, stymulując rozwój turystyki (Campos i in., 2016; Dias i Mendes, 2018).

Jeśli chodzi o korzyści dla konsumentów, oznaczenie produktu gwarantuje jego autentyczność i jakość (Czerwiecki, 2004; Dias i Mendes, 2018). Daje to potencjalnemu nabywcy więcej informacji, które mogą mu pomóc w podejmowaniu decyzji podczas zakupów. Cena przestaje być jedynym lub głównym argumentem na rzecz danego towaru. Zakup produktu staje się początkiem kontaktu z unikatową kulturą, tradycją, historią, społecznością i przyrodą danego obszaru (Török i in., 2020).

Zagadnienia związane z ochroną produktów regionalnych i wytwarzanych tradycyjnymi metodami określone są w prawie Unii Europejskiej w:

- rozporządzeniu Parlamentu Europejskiego i Rady (UE) nr 1151/2012 z dnia 21 listopada 2012 r. w sprawie systemów jakości produktów rolnych i środków spożywczych (Rozporządzenie, 2012);

- rozporządzeniu delegowanym Komisji (UE) nr 664/2014 z dnia 18 grudnia 2013 r. uzupełniającym rozporządzenie Parlamentu Europejskiego i Rady (UE) nr 1151/2012 (Rozporządzenie, 2013, s. 17);
- rozporządzeniu wykonawczym Komisji (UE) nr 668/2014 z dnia 13 czerwca 2014 r. ustanawiającym zasady stosowania rozporządzenia Parlamentu Europejskiego i Rady (UE) nr 1151/2012 w sprawie systemów jakości produktów rolnych i środków spożywczych (Rozporządzenie, 2014, s. 36).

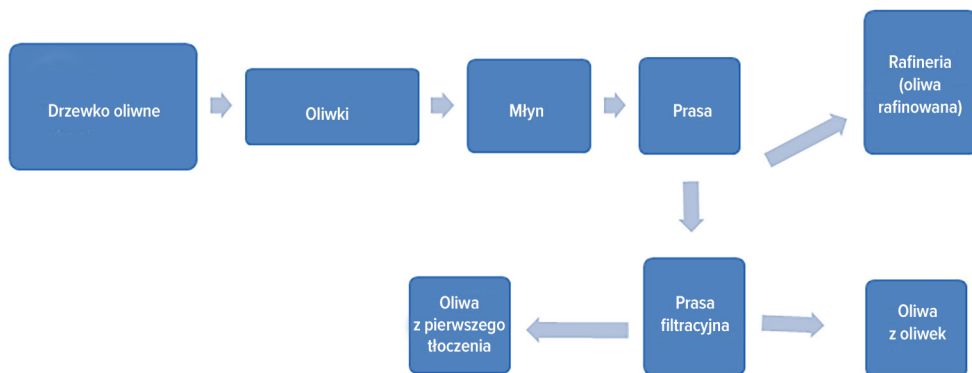
Przykładem zastosowania omawianych technologii są monitorowanie i ochrona autentyczności wina z określonych regionów. Techniki spektroskopowe umożliwiają identyfikację charakterystycznych cech danego wina, takich jak kwasowość, zawartość alkoholu i składniki mineralne (Hencz i in., 2022). Algorytmy uczenia maszynowego pozwalają na identyfikację wzorców, które wskazują na autentyczność wina, podczas gdy metody teledetekcyjne mogą być używane do monitorowania warunków uprawy winorośli.

Oliwa z oliwek, której schemat wytwarzania przedstawiono na ryc. 2, zwłaszcza w formie pierwotnej tzw. oliwy z pierwszego tłoczenia EVOO (ang. *extra virgin olive oil*), jest jednym z najczęściej fałszowanych produktów. Do przyczyn tego zjawiska należą:

- 1) chęć osiągnięcia zysku pieniężnego;
- 2) sprzedaż zafałszowanej oliwy z domieszką tańszych olejów m.in. sojowego za niższą cenę, zwiększenie konkurencji cenowej na rynku kosztem oryginalnej 100% oliwy z oliwek;
- 3) globalizacja, zmiany klimatyczne i wzrost kosztów produkcji żywności.

Efektywnymi, a przy tym nieinwazyjnymi narzędziami do identyfikacji produktu są w tym przypadku spektroskopia NIR i MIR (w zakresie średniej podczerwieni) oraz wykorzystanie do interpretacji danych algorytmów klasyfikujących i segmentacji danych – ANOVA, testów Kruskala-Wallisa, analizy głównych składowych czy hierarchicznej analizy klastrowej (Chakravartula i in., 2022). Jakkolwiek brakuje tutaj nieco bardziej wyrafinowanych i przy tym nadal ekonomicznych metod wykrywania denominacji, szanse stwarzają techniki ultrasprawnej chromatografii cieczowej sprzężonej z detektorem wyładowań koronowych (Green i in., 2020).

Regionalne sery to kolejny lokalny produkt z kategorii PDO (*protected designation of origin*). Zapewnianie autentyczności fety ma duże znaczenie dla greckiej gospodarki (Dias i Mendes, 2018) i może być dobrym przykładem, jak implementować metody potwierdzania oryginalności wyrobu oraz użytych surowców w przypadku polskich czy małopolskich mleczarskich produktów regionalnych, takich jak bryndza czy oscypek. Techniki te mogą być oparte na identyfikacji mikrobiologicznej (biosensory) i genetycznej (reakcja łańcuchowa polimerazy, PCR) szczepów mikroorganizmów obecnych w procesie produkcji sera, jak również unikalnych parametrów organoleptycznych surowca czy produktu finalnego zintegrowanych z danymi agronomicznymi hodowli czy uprawy oraz specyfiką regionu (składniki mineralne gleby).



Ryc. 2. Schemat produkcji oliwy z oliwek

Źródło: opracowanie własne

6. Podsumowanie

W Polsce jednostką odpowiedzialną za prowadzenie systemu rejestracji produktów o określonym pochodzeniu geograficznym i specyficznej, tradycyjnej jakości w rozumieniu przepisów unijnych jest Ministerstwo Rolnictwa i Rozwoju Wsi, zgodnie z Ustawą z dnia 9 marca 2023 r. o rejestracji i ochronie nazw pochodzenia, oznaczeń geograficznych oraz gwarantowanych tradycyjnych specjalności produktów rolnych i środków spożywczych, win lub napojów spirytusowych oraz o produktach tradycyjnych. Ten akt prawny mówi także o polskiej Liście produktów tradycyjnych zawierającej wyroby, których jakość lub wyjątkowe cechy i właściwości wynikają ze stosowania tradycyjnych metod produkcji (wykorzystywanych od co najmniej 25 lat) i które stanowią element dziedzictwa kulturowego regionu (Ustawa, 2023).

Pochodzenie geograficzne staje się kluczowym elementem promocji artykułów spożywczych. Konsumentom zależy na autentyczności, producenci z kolei poszukują sposobów na wyróżnienie swoich wyrobów.

Dla regionu Małopolski opisane technologie mogą okazać się szczególnie przydatne ze względu na bogactwo unikatowych produktów lokalnych. Techniki spektroskopowe wspomogłyby ich ochronę, pomagając w walidacji pochodzenia i autentyczności.

Przykładowo obecnie w łańcuchu produkcji mleka i zwłaszcza regionalnych wyrobów mleczarskich cyfryzacja jest ograniczona. Wprowadzenie zintegrowanych systemów fotoniki, uczenia maszynowego i teledetekcji umożliwiłoby hodowcom bydła mlecznego optymalizację działań oraz zabezpieczenie oznaczeń pochodzenia i jakości odbieranego od nich mleka. Ponadto producenci nabiału stosują skomplikowane i czasem wymagające dużej ilości papieru procesy rejestrowania źródeł

zebranego mleka, a także zachowywania informacji o jego jakości. Brak kompleksowego i niezmiennego zestawu informacji – opartego choćby na systemie *blockchain* – stwarza okazje do fałszowania żywności, np. poprzez mieszanie różnych partii mleka o odmiennych właściwościach.

Algorytmy uczenia maszynowego mogą się zatem przyczynić do automatyzacji procesów produkcyjnych i logistycznych, co przełożyłoby się na większą efektywność i konkurencyjność lokalnego rolnictwa. Konieczne jest szeroko zakrojone działanie i tworzenie nowych projektów opartych zarówno na programach unijnych, jak i na funduszach regionalnych oraz programach celowych przeznaczonych do wspierania tego rodzaju aktywności.

Literatura

- Campos, B. E., Ruivo, T. D., da Silva Scapim, M. R., Madrona, G. S., Bergamasco, R. D. (2016). Optimization of the mucilage extraction process from chia seeds and application in ice cream as a stabilizer and emulsifier. *LWT – Food Science and Technology*, 65, 874–883. <https://doi.org/10.1016/j.lwt.2015.09.021>
- Chakravartula, S. S. N., Moschetti, R., Bedini, G., Nardella, M., Massantini, R. (2022). Use of convolutional neural network (CNN) combined with FT-NIR spectroscopy to predict food adulteration: A case study on coffee. *Food Control*, 135, 108816. <https://doi.org/10.1016/j.foodcont.2022.108816>
- Cisternas, I., Velásquez, I., Caro, A., Rodríguez, A. (2020). Systematic literature review of implementations of precision agriculture. *Computers and Electronics in Agriculture*, 176, 105626. <https://doi.org/10.1016/j.compag.2020.105626>
- Ciulu, M., Oertel, E., Serra, R., Farre, R., Spano, N., Caredda, M., Malfatti, L., Sanna, G. (2021). Classification of Unifloral Honeys from Sardinia (Italy) by ATR-FTIR Spectroscopy and Random Forest. *Molecules*, 26(1), 88. <https://doi.org/10.3390/MOLECULES26010088>
- Cubero-Leon, E., Peñalver, R., Maquet, A. (2014). Review on metabolomics for food authentication. *Food Research International*, 60, 95–107. <https://doi.org/10.1016/j.foodres.2013.11.041>
- Czerwiecki, L. (2004). Problemy autentyczności produktów spożywczych. *Roczniki Państwowego Zakładu Higieny*, 55(1), 9–19.
- Danezis, G. P., Tsagkaris, A. S., Camin, F., Brusci, V., Georgiou, C. A. (2016). Food authentication: Techniques, trends & emerging approaches. *TrAC Trends in Analytical Chemistry*, 85(A), 123–132. <https://doi.org/10.1016/j.trac.2016.02.026>
- Dias, C., Mendes, L. (2018). Protected Designation of Origin (PDO), Protected Geographical Indication (PGI) and Traditional Speciality Guaranteed (TSG): A bibliometric analysis. *Food Research International*, 103, 492–508. <https://doi.org/10.1016/j.foodres.2017.09.059>
- Didham, M., Truong, V. K., Chapman, J., Cozzolino, D. (2020). Sensing the Addition of Vegetable Oils to Olive Oil: The Ability of UV-VIS and MIR Spectroscopy Coupled with Che-

- metric Analysis. *Food Analytical Methods*, 13(3), 601–607. <https://doi.org/10.1007/s12161-019-01680-8>
- Elmasry, G., Kamruzzaman, M., Sun, D.-W., Allen, P. (2012). Principles and Applications of Hyperspectral Imaging in Quality Evaluation of Agro-Food Products: A Review. *Critical Reviews in Food Science and Nutrition*, 52(11), 999–1023. <https://doi.org/10.1080/10408398.2010.543495>
- Feng, L., Wu, B., Zhu, S., He, Y., Zhang, C. (2021). Application of Visible/Infrared Spectroscopy and Hyperspectral Imaging With Machine Learning Techniques for Identifying Food Varieties and Geographical Origins. *Frontiers in Nutrition*, 8. <https://doi.org/10.3389/fnut.2021.680357>
- Fuentes, S., Torrico, D. D., Tongson, E., Viejo, C. G. (2020). Machine Learning Modeling of Wine Sensory Profiles and Color of Vertical Vintages of Pinot Noir Based on Chemical Fingerprinting, Weather and Management Data. *Sensors*, 20(13), 3618. <https://doi.org/10.3390/s20133618>
- Garrido, F., Caranqui, V. (2020). Pasture Monitoring Applying Normalized Difference Vegetation Index (NDVI) Time Series with Sentinel-2 and Landsat 8 Images, to Improve Milk Production at Santa Mónica Farm, Imbabura, Ecuador, (w:) *Computational Science and Its Applications – ICCSA 2020*, O. Gervasi, B. Murgante, S. Misra, C. Garau, I. Blečić, D. Taniar, B. O. Apduhan, A. M. A. C. Rocha, E. Tarantino, C. M. Torre, Y. Karaca (red.). *Lecture Notes in Computer Science*, 12254, 560–575. https://doi.org/10.1007/978-3-030-58817-5_41
- González-Domínguez, R. (2022). Food Authentication: Techniques, Trends and Emerging Approaches (Second Issue). *Foods*, 11(13), 10–12. <https://doi.org/10.3390/foods11131926>
- Green, H. S., Li, X., De Pra, M., Lovejoy, K. S., Steiner, F., Acworth, I. N., Wang, S. C. (2020). A rapid method for the detection of extra virgin olive oil adulteration using UHPLC-CAD profiling of triacylglycerols and PCA. *Food Control*, 107, 106773. <https://doi.org/10.1016/j.foodcont.2019.106773>
- Grunert, K. G., Achmann, K. (2016). Consumer reactions to the use of EU quality labels on food products: A review of the literature. *Food Control*, 59, 178–187. <https://doi.org/10.1016/j.foodcont.2015.05.021>
- Hakkel, K. D., Petruzzella, M., Ou, F., van Klinken, A., Pagliano, F., Liu, T., van Veldhoven, R. P. J., Fiore, A. (2022). Integrated near-infrared spectral sensing. *Nature Communications*, 13, 103. <https://doi.org/10.1038/s41467-021-27662-1>
- Haque, E., Taniguchi, H., Hassan, M., Bhowmik, P., Karim, M. R., Śmiech, M., Zhao, K., Rahman, M., Islam, T. (2018). Application of CRISPR/Cas9 Genome Editing Technology for the Improvement of Crops Cultivated in Tropical Climates: Recent Progress, Prospects, and Challenges. *Frontiers in Plant Science*, 9. <https://doi.org/10.3389/fpls.2018.00617>
- Hencz, A., Nguyen, L. L. P., Baranyai, L., Albanese, D. (2022). Assessment of Wine Adulteration Using Near Infrared Spectroscopy and Laser Backscattering Imaging. *Processes*, 10(1), 95. <https://doi.org/10.3390/pr10010095>
- Huang, F., Song, H., Guo, L., Guang, P., Yang, X., Li, L., Zhao, H., Yang, M. (2020). Detection of adulteration in Chinese honey using NIR and ATR-FTIR spectral data fusion. *Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy*, 235, 118297. <https://doi.org/10.1016/j.saa.2020.118297>

- Leo, M., Sharma, S., Maddulety, K. (2019). Machine Learning in Banking Risk Management: A Literature Review. *Risks*, 7(1), 29. <https://doi.org/10.3390/risks7010029>
- Marengo, L. F. L., de Oliveira, L. P., Vale, D. L., Salles, M. O. (2021). Predicting Vodka Adulteration: A Combination of Electronic Tongue and Artificial Neural Networks. *Journal of the Electrochemical Society*, 168(11), 117513. <https://doi.org/10.1149/1945-7111/ac393e>
- Mastilović, J., Kukulj, D., Kevrešan, Ž., Ostojić, G., Kovač, R., Đerić, M., Ubiparip Samek, D. (2023). Emerging Perspectives of Blockchains in Food Supply Chain Traceability Based on Patent Analysis. *Foods*, 12(5), 1036. <https://doi.org/10.3390/foods12051036>
- Montowska, M., Alexander, M. R., Tucker, G. A., Barrett, D. A. (2015). Authentication of processed meat products by peptidomic analysis using rapid ambient mass spectrometry. *Food Chemistry*, 187, 297–304. <https://doi.org/10.1016/j.foodchem.2015.04.078>
- Qin, T. (2020). *Machine Learning Basics*, (w:) Dual Learning, T. Qin (red.). Singapore: Springer Singapore, 11–23. https://doi.org/10.1007/978-981-15-8884-6_2
- Revelou, P.-K., Pappa, C., Kakouri, E., Kanakis, C. D., Papadopoulos, G. K., Pappas, C. S., Tarantilis, P. A. (2021). Discrimination of botanical origin of olive oil from selected Greek cultivars by SPME-GC-MS and ATR-FTIR spectroscopy combined with chemometrics. *Journal of the Science of Food and Agriculture*, 101(7), 2994–3002. <https://doi.org/10.1002/jsfa.10932>
- Rozporządzenie (2012). Rozporządzenie Parlamentu Europejskiego i Rady (UE) nr 1151/2012 z dnia 21 listopada 2012 r. w sprawie systemów jakości produktów rolnych i środków spożywczych. *Dziennik Urzędowy Unii Europejskiej*, L 343/1.
- Rozporządzenie (2013). Rozporządzenie delegowane Komisji (UE) nr 664/2014 z dnia 18 grudnia 2013 r. uzupełniające rozporządzenie Parlamentu Europejskiego i Rady (UE) nr 1151/2012 w odniesieniu do ustanowienia symboli unijnych dotyczących chronionych nazw pochodzenia, chronionych oznaczeń geograficznych i gwarantowanych tradycyjnych specjalności oraz w odniesieniu do niektórych zasad dotyczących pochodzenia paszy i surowców, niektórych przepisów proceduralnych i niektórych dodatkowych przepisów przejściowych. *Dziennik Urzędowy Unii Europejskiej*, L 179/17.
- Rozporządzenie (2014). Rozporządzenie wykonawcze Komisji (UE) nr 668/2014 z dnia 13 czerwca 2014 r. ustanawiające zasady stosowania rozporządzenia Parlamentu Europejskiego i Rady (UE) nr 1151/2012 w sprawie systemów jakości produktów rolnych i środków spożywczych. *Dziennik Urzędowy Unii Europejskiej*, L 179/36.
- Sitokonstantinou, V., Koutroumpas, A., Drivas, T., Koukos, A., Karathanassi, V., Kontoes, H., Papoutsis, I. (2020). A Sentinel based agriculture monitoring scheme for the control of the CAP and food security, (w:) Eighth International Conference on Remote Sensing and Geoinformation of the Environment (RSCy2020), K. Themistocleous, G. Papadavid, S. Michaelides, V. Ambrosia, D. G. Hadjimitsis (red.). *Proceedings*, 11524. <https://doi.org/10.1117/12.2571721>
- Sousa, G. P. B. de, Tayebi, M., Campos, L. R., Greschuk, L. T., Amorim, M. T. A., Rosas, J. T. F., Mello, F. A. O., Chen, S., Ayoubi, S., Demattê, J. A. M. (2023). Improvement of spatial prediction of soil depth via earth observation. *CATENA*, 223, 106915. <https://doi.org/10.1016/j.catena.2023.106915>
- Stombaugh, T. (2018). *Satellite-Based Positioning Systems for Precision Agriculture*, (w:) *Precision Agriculture Basics*, D. K. Shannon, D. E. Clay, N. R. Kitchen (red.). American

- Society of Agronomy, Crop Science Society of America, and the Soil Science Society of America, 25–35. <https://doi.org/10.2134/precisionagbasics.2017.0036>
- Targoński, Z., Stój, A. (2005). Zafałszowania żywności i metody ich wykrywania. *Żywność. Nauka. Technologia. Jakość*, 12, 4(45), Suplement, 30–40.
- Taylan, O., Cebi, N., Yilmaz, M. T., Sagdic, O., Ozdemir, D., Balubaid, M. (2021). Rapid detection of green-pea adulteration in pistachio nuts using Raman spectroscopy and chemometrics. *Journal of the Science of Food and Agriculture*, 101(4), 1699–1708. <https://doi.org/10.1002/jsfa.10845>
- Török, Á., Jantyk, L., Maró, Z. M., Moir, H. V. J. (2020). Understanding the Real-World Impact of Geographical Indications: A Critical Review of the Empirical Economic Literature. *Sustainability*, 12(22), 9434. <https://doi.org/10.3390/su12229434>
- Ustawa (2023). Ustawa z dnia 9 marca 2023 r. o rejestracji i ochronie nazw pochodzenia, oznaczeń geograficznych oraz gwarantowanych tradycyjnych specjalności produktów rolnych i środków spożywczych, win lub napojów spirytusowych oraz o produktach tradycyjnych. *Dziennik Ustaw*, poz. 588. <https://isap.sejm.gov.pl/isap.nsf/download.xsp/WDU20230000588/T/D20230588L.pdf>, data dostępu: 24.11.2023.
- Yoon, H., Lee, J. (2022). Hyperspectral Image Visualization through Neural Network for the Food Industry, (w:) 2022 12th Workshop on Hyperspectral Imaging and Signal Processing: Evolution in Remote Sensing (WHISPERS). <https://doi.org/10.1109/WHISPERS56178.2022.9955049>