


Wdrażamy nanobiosensoryczne rolnictwo w celu produkcji zdrowej żywności


w oparciu o zrównoważone praktyki z zachowaniem równowagi ekologicznej ekosystemu

Wykorzystanie dronów, zdjęć satelitarnych i biosensorów umożliwia monitorowanie stanu upraw w czasie rzeczywistym, optymalizując podejmowanie decyzji i minimalizując poniesione nakłady. Zastosowane biosensory elektrofizjologiczne są wykorzystywane do diagnozowania stanu zdrowia roślin i identyfikacji stresów biotycznych i abiotycznych. Są to czujniki nowej generacji, które przekazują informacje o zdrowiu rośliny zanim pojawią się widoczne oznaki stresu, jak również uniwersalne nanosensory do wykrywania hormonów roślinnych, między innymi hormonu auksyny, który jest odpowiedzialny za rozwój i wzrost rośliny. Takie innowacje poprawiają wydajność produkcyjną i zmniejszają wpływ na środowisko (Rys.1).


Następnie algorytmy sztucznej inteligencji i uczenia maszynowego przetwarzają te „duże dane”, aby zoptymalizować nawadnianie, nawożenie, a nawet zwalczanie szkodników, dostosowane dokładnie do potrzeb rośliny (Rys. 2 i 3). Dzięki tym rozwiązaniom można poprawić jakość upraw, zmniejszyć ilość odpadów i promować zrównoważony rozwój w aspekcie produktywności i ochrony środowiska.



Rys. 1. Moduły czujników środowiskowych i fizjologicznych z dedykowaną elektroniką do zasilania i komunikacji są rozmieszczone w uprawach i bezprzewodowo połączone z centralnym procesorem [1].




Rys. 2. System rozmieszczenia czujników i zbierania danych [2].



Rys.3. Wzorcowe centrum aplikacji inteligentnego rolnictwa opartych na IoT [3].

Rola biosensorów w nowoczesnym przetwórstwie żywności jest nieodłączna. Przemysł spożywczy wykorzystuje szeroką gamę biosensorów, aby zapewnić bezpieczeństwo żywności, utrzymać jakość i efektywność produkcji (Rys. 4).


Zapewniają one precyzyjne monitorowanie parametrów technologicznych, takich jak temperatura, wilgotność, stopień rozdrobnienia i ciśnienie w całym procesie produkcji żywności (Rys. 5), parametrów jakościowych żywności, identyfikacji zanieczyszczeń, patogenów metodami nieniszczącymi (Tabela, Rys. 6) oraz mają szerokie zastosowanie w automatyzacji procesów produkcyjnych.



Rys. 4. Zastosowanie nanosensorów w przemyśle spożywczym.



Rys. 5. Kontrola parametrów procesu produkcyjnego za pomocą biosensorów



B[Electronic Tongue]



Rys. 6. Elektroniczny nos do wykrywania zanieczyszczeń, stopnia zepsucia produktu [4].

Tabela. Zastosowanie biosensorów do określenia parametrów jakościowych produktów [4].


Various studies on Biosensors application in food:

Media/ food	Detection/ determination	Ref.
Meat	Glucose gradient	(Maines, 1996)
Fish	Determination of K-value Determination of Trimethylamine	(Mitsubayashi., 2004)
Milk	Presence of urea determination of lactose concentration	(Meshram, 2018)
Wine	Determination of sulphur dioxide Mycotoxins detection Heavy metals detection Detection of tastants and suppression of sourness	(Meshram, 2018) (Hosnedlova, 2019) (Odobasić et al, 2019) (CamaraMartos, 2016)
	by the sweetness Determination of histamine Separation of yeast cells in sparkling	(RiulJ_unior, 2003) (Berovic, 2014)
Fresh fruits and vegetable	Fruit acids Concentration of total soluble solids Total titratable acidity	(Meshram, 2018)
Fruit juices	Determination of ascorbic acid	(Meshram, 2018)
Tea	Detection of polyphenols	(Forzato et al, 2020)


Do oceny jakości żywności metodą nieniszczącą zastosowane są czujniki optyczne z uczeniem maszynowym. Czujniki optyczne rejestrują parametry światła widzialnego oraz fali elektromagnetycznej generowanej w wyniku fluorescencji, odbicia, rozpraszania. Umożliwiają one szybkie i ekonomiczne gromadzenie danych bez uszkodzania próbek żywności. Modele uczenia maszynowego mogą analizować te dane z czujników optycznych w celu przewidywania określonych cech jakościowych. Rys. 7 przedstawia proces rejestracji danych za pomocą czujników optycznych, analizę danych za pomocą uczenia maszynowego i udostępnianie danych serwerom w chmurze w celu testowania modelu.



Nieniszcząca ocena jakości żywności przy użyciu uczenia maszynowego i sensorów optycznych. Najczęstszymi metodami zbierania danych są obrazowanie hiperspektralne (HSI), spektroskopia bliskiej podczerwieni (NIR), spektroskopia Ramana, smartfony i obrazowanie odbiciowe o strukturalnym oświetleniu (SIFT) [5, 6].




Do analizy danych stosuje się selekcję parametrów w celu wybrania krytycznych cech widmowych, podczas gdy segmentacja obrazu służy do wyodrębnienia krytycznych cech obrazu. Do oceny jakości żywności stosuje się różne modele uczenia maszynowego (modele klasyfikacji lub regresji).




Rys. 7. Przegląd nieniszczącej oceny jakości przy użyciu biosensorów i uczenia maszynowego w celu oceny jakości żywności i sterowania robotami [5].


Przykłady zastosowania widzenia komputerowego, dziedziny sztucznej inteligencji (AI), która łączy uczenie maszynowe i czujniki optyczne do analizy jakości żywności, a następnie kierowania robotami w celu zautomatyzowanego zbioru, sortowania, klasyfikowania i przetwarzania żywności (Rys. 8).




Pięciopalczasty robot do zbioru truskawek przy użyciu modelu YOLOv4.




(b) Roboty do zbioru jabłek wykorzystują system próżniowy oraz kamery RGB i sensory laserowe, z zastosowaniem splotowych (lub inaczej konwolucyjne) sieci neuronowych (CNN, ang. *convolutional neural networks*) jako algorytmu AI stosowanego w przetwarzaniu obrazów



(c) Robot sortujący i klasyfikujący owoc przy użyciu kamery RGB i modelu YOLOv3



(d) Prognozowanie punktu chwytania tuszy w celu zautomatyzowanego krojenia mięsa przy użyciu obrazowania RGB, modelu U-Net i robota.



(e) Określenie trajektorii cięcia przy użyciu obrazowania tomografii komputerowej (TK) i modelu U-Net dla systemu automatyzacji aseptycznej.

Rys. 8 (a, b, c, d, e). Przykłady współdziałania biosensorów z robotami [5].

Zastosowanie biosensorów i uczenia maszynowego do oceny jakości żywności, a także zastosowanie wizji komputerowej i robotyki do automatyzacji przetwarzania wysokiej jakości żywności staje się dzisiaj ważnym elementem życia gospodarczego oraz poprawy jakości życia. Modele uczenia maszynowego, których istotą jest nawiązanie interakcji ze środowiskiem na podstawie zebranych informacji mogą wyodrębniać i uczyć się cech z danych wielowymiarowych i na tej podstawie dokładnie prognozować jakość żywności. Aby opracować optymalny model uczenia maszynowego, algorytmy powinny być wybierane i porównywane na podstawie testów badawczych, a także rozmiaru i charakteru zestawu danych. Systemy te umożliwiają ocenę jakości produktu w czasie rzeczywistym i mają duży potencjał aplikacyjny dotyczący automatyzacji zbioru, sortowania i przetwarzania żywności.

Literatura

1. Steeneken, Peter G.; Kaiser, Elias; Verbiest, Gerard J.; Ten Veldhuis, Marie Claire, *Sensors in agriculture towards an Internet of Plants*, Nature Reviews Methods Primers August 2023. DOI:10.1038/s43586-023-00250-x.
2. K.R. Gsangaya, S.S.H. Hajjaj, M.T.H. Sultan, L.S. Hua, *Portable, wireless, and effective internet of things-based sensors for precision agriculture*, Int. J. Environ. Sci. Technol. (2020), <https://doi.org/10.1007/s13762-020-02737-6>.
3. Awais Ali ,Tajamul Hussain, Noramon Tantashutikun, Nurda Hussain and Giacomo Cocetta. *Application of Smart Techniques, Internet of Things and Data Mining for Resource Use Efficient and Sustainable Crop Production*, Agriculture 2023, 13. DOI:10.3390/agriculture13020397
4. Nidhi Sharma, Manasi Anil Choudhari, Devesh Nagesh Dabhade, Suhasi Jivan Bari, *Sensors in Food Industry*, International Journal of Advanced Research in Science, Communication and Technology (IJARSCT), Journal Volume 4, Issue 4, March 2024. DOI: 10.48175/IJARSCT-15924.
5. In-Hwan Lee and Luyao Ma, *Integrating machine learning, optical sensors, and robotics for advanced food quality assessment and food processing*, Food Innovation and Advances 2025, 4(1): 65–72, <https://doi.org/10.48130/fia-0025-0007>.
6. Saletnik A.; Saletnik B.; Puchalski Cz., *Raman Method in Identification of Species and Varieties, Assessment of Plant Maturity and Crop Quality—A Review*, Molecules 2022, 27(14), 4454; <https://doi.org/10.3390/molecules27144454>.

Dziekan

Wydziału Technologiczno-Przyrodniczego

prof. dr hab. inż. Czesław Puchalski