

Application of artificial intelligence in the optimization of mineral fertilization and nutrient balance in precision agriculture

Zastosowanie sztucznej inteligencji w optymalizacji nawożenia mineralnego i bilansu składników pokarmowych w rolnictwie precyzyjnym



DOI: 10.15199/62.2026.8.10

A review on precision agriculture, nutrient balance models, NUE, AI applications in agriculture, and the role of MRV in climate policy. A hybrid research model combining soil, meteorol., remote sensing, and operational data with machine learning algorithms and a nutrient balance model, was proposed. A model case study was presented for a farm in Central Europe, comparing a conventional fertilization scenario with an AI-supported variable-rate fertilization approach. The use of AI can reduce N fertilizer consumption, improve N use efficiency, reduce N₂O emissions, and improve farm economic performance.

Keywords: artificial intelligence, precision agriculture, mineral fertilization, nitrogen use efficiency, nutrient balance, MRV, N₂O emissions

W opracowaniu zaprezentowano najnowszy przegląd literatury dotyczący rolnictwa precyzyjnego, modeli bilansu składników pokarmowych, efektywności nawożenia (NUE), zastosowań AI w rolnictwie oraz roli MRV (*monitoring, reporting, verification*) w politykach klimatycznych. Zaproponowano hybrydowy model badawczy łączący dane glebowe, meteorologiczne, teledetekcyjne i operacyjne z algorytmami uczenia maszynowego oraz modelem bilansu składników pokarmowych. Przedstawiono modelowe studium przypadku dla gospodarstwa z Europy Środkowej, w którym porównano scenariusz tradycyjnego nawożenia z podejściem opartym na AI i zmiennym dawkowaniem nawozów. Zastosowanie AI może przyczynić się do zmniejszenia zużycia nawozów azotowych, poprawy efektywności wykorzystania azotu, ograniczenia emisji N₂O oraz poprawy wyniku ekonomicznego gospodarstwa. Artykuł wnosi wkład do literatury poprzez zaproponowanie zintegrowanego ujęcia łączącego AI, bilans składników pokarmowych i MRV w ramach jednego modelu analitycznego, osadzonego w kontekście transformacji rolnictwa w kierunku systemów niskoemisyjnych, cyfrowych i opartych na analizie danych.

Słowa kluczowe: sztuczna inteligencja, rolnictwo precyzyjne, nawożenie mineralne, efektywność wykorzystania azotu, bilans składników pokarmowych, MRV, emisje N₂O



Dr Grzegorz KĄDZIELAWSKI (ORCID: 0000-0003-0804-2232) ukończył studia w Instytucie Administracyjno-Ekonomicznym Państwowej Wyższej Szkoły Zawodowej w Tarnowie oraz na Wydziale Prawa i Administracji Uniwersytetu Jagiellońskiego. W 2017 r. uzyskał stopień doktora nauk prawnych na Wydziale Prawa, Administracji i Stosunków Międzynarodowych Krakowskiej Akademii im. Andrzeja Frycza Modrzewskiego. Jest dyrektorem Instytutu Badań nad Sztuczną Inteligencją i adiunktem w Katedrze Zarządzania Akademii WSB w Dąbrowie Górniczej. W przeszłości był wiceprezesem zarządu Grupy Azoty SA i przewodniczył Radzie Nadzorczej Grupy Azoty Poliolefin SA. Jest członkiem Stowarzyszenia Inżynierów i Techników Przemysłu Chemicznego. Jest autorem lub współautorem wielu specjalistycznych książek i artykułów publikowanych w czasopiśmie branżowych. Specjalność – zarządzanie innowacjami.

*** Adres do korespondencji:**

Katedra Zarządzania, Akademia WSB w Dąbrowie Górniczej, ul. Cieplaka 1c, 41-300 Dąbrowa Górnicza, tel.: +48 692-898-014, e-mail: gkadzielawski@wsb.edu.pl



Prof. dr hab. inż. Janusz IGRAS (ORCID: 0009-0009-7173-0733) w roku 1989 ukończył studia na Wydziale Rolniczym Akademii Rolniczej w Lublinie (obecnie Uniwersytet Przyrodniczy w Lublinie). Jest profesorem w Katedrze Chemii Rolnej i Środowiskowej na Wydziale Agrobiotechnologii UP w Lublinie. W latach 2011–2017 był dyrektorem naukowym w Sieci Badawcza Łukasiewicz – Instytucie Nowych Syntezy Chemicznych w Puławach, w latach 2017–2024 pełnił funkcję dyrektora tego Instytutu, a w latach 1990–2011 pracował w Instytucie Uprawy Nawożenia i Gleboznawstwa – Państwowym Instytucie Badawczym w Puławach. Profesor J. Igras był wieloletnim członkiem Rady Głównej Nauki i Szkolnictwa Wyższego, Rady Głównej Instytutów Badawczych, Rady Polskiej Izby Przemysłu Chemicznego oraz przewodniczącym Rady Naukowej Centrum

Kompetencji Puławy przy Grupie Azoty Puławy. Obecnie jest członkiem Rady Naukowej Instytutu Katalizy i Fizykochemii Powierzchni PAN im. Jerzego Habera. Specjalność – nawozy i nawożenie, chemia rolna.

Współczesne rolnictwo stoi wobec bezprecedensowego wyzwania polegającego na jednoczesnym zwiększaniu produkcji żywności oraz ograniczaniu negatywnego wpływu na środowisko naturalne. Zgodnie z prognozami FAO¹⁾ popyt na żywność do połowy XXI w. będzie nadal wzrastać wraz ze wzrostem liczby ludności oraz zmianami wzorców konsumpcji, co zwiększa presję na intensyfikację produkcji rolnej. Jednocześnie sektor AFOLU, obejmujący rolnictwo, leśnictwo i użytkowanie gruntów, odpowiada za istotną część globalnych emisji antropogenicznych gazów cieplarnianych, a samo rolnictwo pozostaje ważnym źródłem emisji metanu i podtlenku azotu²⁾.

W tym kontekście rosnące znaczenie zyskują strategie poprawy efektywności wykorzystania składników pokarmowych, w szczególności azotu, określane jako efektywność wykorzystania azotu NUE (*nitrogen use efficiency*). Mała efektywność nawożenia pozostaje jednym z głównych problemów współczesnego rolnictwa. W praktyce znaczna część azotu wprowadzanego do systemu nie jest pobierana przez rośliny, lecz ulega stratom wskutek ulatniania do atmosfery, denitryfikacji oraz wymywania do wód, co generuje zarówno koszty ekonomiczne, jak i negatywne skutki środowiskowe^{3, 4)}. Straty te przyczyniają się do eutrofizacji wód, pogorszenia jakości powietrza oraz wzrostu emisji gazów cieplarnianych⁵⁾. Odpowiedzią na te wyzwania jest dynamiczny rozwój rolnictwa precyzyjnego w ostatnich latach, którego ideą jest dostosowanie praktyk agrotechnicznych do zmienności przestrzennej i czasowej warunków glebowych, klimatycznych oraz potrzeb pokarmowych roślin. Wykorzystanie technologii, takich jak systemy GPS, GIS, czujniki Internetu Rzeczy, IoT (*Internet of Things*) oraz dane satelitarne, w tym np. dane z programu Copernicus, umożliwia gromadzenie dużych wolumenów danych opisujących stan upraw i gleby w czasie rzeczywistym⁶⁾. Jednak sama dostępność danych nie gwarantuje jeszcze poprawy jakości decyzji nawozowych. Kluczowym wyzwaniem staje się ich analiza, integracja i przekształcenie w praktyczne zalecenia operacyjne na polu. W tym miejscu istotną rolę zaczyna odgrywać sztuczna inteligencja (AI). Dzięki zastosowaniu algorytmów uczenia maszynowego i głębokiego uczenia możliwe staje się modelowanie złożonych, nieliniowych relacji między warunkami środowiskowymi, stanem roślin i prognozowanymi plonami^{7, 8)}. Modele AI mogą wspierać zarówno predykcję plonów, jak i dynamiczną optymalizację dawek nawozów, uwzględniając aktualne warunki glebowe, pogodowe i przestrzenne zróżnicowanie pola. Szczególnie istotne są najnowsze badania nad efektywnością ekonomiczną wykorzystania azotu, tzw. *variable-rate nitrogen prescriptions*⁷⁻⁹⁾. Z badań wielu autorów wynika, że skuteczne systemy wspomagania decyzji nawozowych powinny integrować dane bieżące i historyczne, a nie opierać się wyłącznie na jednym źródle informacji⁷⁻¹¹⁾.

Pomimo rosnącej liczby publikacji dotyczących zastosowania AI w rolnictwie, nadal widoczna jest luka badawcza w obszarze integracji modeli sztucznej inteligencji z kla-

sycznymi modelami bilansu składników pokarmowych oraz z rozbudowanymi systemami MRV (*monitoring, reporting, verification*), obejmującymi monitoring upraw i środowiska, raportowanie danych oraz ich weryfikację. Problem ten jest szczególnie istotny w kontekście rosnących wymagań regulacyjnych związanych z raportowaniem efektów środowiskowych i rozwojem mechanizmów certyfikacji działań klimatycznych w rolnictwie. Systemy MRV wymagają bowiem nie tylko danych o wysokiej jakości, lecz także transparentnych metod modelowania i walidacji wyników.

W literaturze podkreśla się również znaczenie podejścia systemowego, które łączy aspekty produkcyjne, środowiskowe i ekonomiczne. Tradycyjne modele nawożenia, oparte na statycznych zaleceniach, często nie uwzględniają w wystarczającym stopniu zmienności przestrzennej, sezonowej dynamiki warunków oraz interakcji pomiędzy czynnikami glebowymi, klimatycznymi i biologicznymi^{10, 11)}. Wykorzystanie statycznych modeli zaleceń nawozowych może prowadzić zarówno do stosowania zbyt małych dawek nawozów, jak i do ich przewymiarowania. Zastosowanie AI otwiera możliwości przejścia od modeli deterministycznych do adaptacyjnych systemów decyzyjnych, uczących się na podstawie danych historycznych i bieżących.

Wkład tego artykułu do literatury polega na 3 elementach. Po pierwsze, artykuł porządkuje i integruje rozproszone w literaturze podejścia dotyczące AI, bilansu składników pokarmowych i systemów MRV. Po drugie, proponuje hybrydowy model analityczny łączący modele procesowe i modele *data-driven* w kontekście optymalizacji nawożenia. Po trzecie, przedstawia modelowe studium przypadku, które ilustruje potencjalne efekty środowiskowe i ekonomiczne wdrożenia takiego podejścia w gospodarstwie rolnym.

Celem publikacji było opracowanie i analiza podejścia integrującego sztuczną inteligencję z modelami bilansu składników pokarmowych w kontekście rolnictwa precyzyjnego. Artykuł koncentruje się na ocenie potencjału AI w zakresie optymalizacji nawożenia mineralnego, poprawy efektywności wykorzystania składników pokarmowych oraz zmniejszenia negatywnych skutków nawożenia na środowisko. Dodatkowo przeanalizowano w nim możliwość wykorzystania takich rozwiązań w systemach MRV, co ma znaczenie dla rozwoju rynków środowiskowych oraz wdrażania polityk klimatycznych. Dla realizacji celu opracowania sformułowano następujące pytania badawcze: (i) P1. W jakim stopniu zastosowanie AI może zwiększyć efektywność nawożenia azotem (NUE) w porównaniu z podejściem tradycyjnym? (ii) P2. Czy wykorzystanie AI może prowadzić do zmniejszenia emisji gazów cieplarnianych oraz strat składników pokarmowych? (iii) P3. W jaki sposób integracja AI z systemami MRV może wspierać certyfikację i raportowanie efektów środowiskowych w rolnictwie?

Odpowiedź na powyższe pytania ma znaczenie zarówno naukowe, jak i praktyczne, wpisując się w szerszy kontekst transformacji sektora rolnego w kierunku lepszego wyko-

rzystania zasobów oraz zmniejszenia emisji składników pokarmowych do środowiska.

Część teoretyczna

Roľnictwo precyzyjne

Roľnictwo precyzyjne wyłoniło się jako odpowiedź na potrzebę zwiększenia efektywności wykorzystania zasobów i zarazem ograniczenia jego wpływu na środowisko. Podejście to opiera się na zarządzaniu zmiennością przestrzenną i czasową w obrębie pola uprawnego z wykorzystaniem technologii, takich jak systemy pozycjonowania satelitarnego (GPS), systemy informacji geograficznej (GIS), czujniki glebowe oraz dane teledetekcyjne¹².

Kluczową rolę w tym systemie odgrywają dane satelitarne, które umożliwiają monitorowanie stanu roślinności w wysokiej rozdzielczości. Wskaźniki, takie jak NDVI (*normalized difference vegetation index*) czy LAI (*leaf area index*) są powszechnie wykorzystywane do oceny stanu odżywienia roślin oraz identyfikacji potencjalnych stref zarządzania składnikami pokarmowymi. Badania wskazują, że wdrożenie roľnictwa precyzyjnego na szerszą skalę może prowadzić do zmniejszenia zużycia nawozów i środków ochrony roślin wraz z jednoczesnym utrzymaniem lub zwiększeniem plonów¹³.

Skuteczność tego podejścia zależy jednak od zdolności do integracji i analizy dużych zbiorów danych. Dodatkowego potwierdzenia użyteczności danych przestrzennych dostarczają badania Fowlera i współpr.¹⁴, którzy wykazali, że długoterminowa analiza przestrzennych wzorców plonowania pozwala identyfikować strefy stabilności plonów i powiązane z nimi atrybuty zdrowotności gleby. Według tych autorów można wykazać, że strefy stałe niskiego plonowania mogą odzwierciedlać mniejszy zwrot węgla do gleby i gorsze właściwości retencyjne, natomiast koncepcja stabilnego plonu może stanowić użyteczną warstwę wejściową podczas budowy map zaleceń dla zmiennego nawożenia. Wnioski te wzmacniają tezę, że dane historyczne o plonach nie są jedynie informacją archiwalną, lecz ważnym komponentem systemów wspierających decyzje nawozowe.

Modele nawożenia i bilansu składników pokarmowych

Modele nawożenia i bilansu składników pokarmowych stanowią fundament agronomicznego podejścia do zarządzania żyznością gleby. Klasyczne podejścia opierają się na równaniu bilansowym, które określa różnicę między dopływami i odpływami składników pokarmowych zgodnie z wytycznymi OECD¹⁵. Modele te uwzględniają takie procesy, jak nawożenie, mineralizacja składników pokarmowych, ich pobranie przez rośliny oraz straty środowiskowe. W praktyce szeroko stosowane są modele procesowe, takie jak DSSAT i APSIM, symulujące wzrost roślin oraz przepływy składników pokarmowych w zależności od

warunków środowiskowych^{10, 16}. Ich ograniczeniem pozostaje jednak wysoka wrażliwość na jakość danych wejściowych oraz konieczność kalibracji do warunków lokalnych. W literaturze coraz częściej podkreśla się potrzebę łączenia modeli procesowych z podejściami opartymi na danych (*data-driven*), w tym z modelami AI.

Sztuczna inteligencja w roľnictwie

Dynamiczny rozwój technologii doprowadził do wyłonienia się nowego paradygmatu w zarządzaniu produkcją roľną, określanego jako roľnictwo oparte na szerokiej analizie wielu danych (*data-driven agriculture*). W jego centrum znajduje się sztuczna inteligencja, rozumiana jako zbiór metod i algorytmów umożliwiających analizę dużych, złożonych zbiorów danych oraz podejmowanie decyzji w warunkach niepewności i zmienności środowiskowej^{6, 7}. W odróżnieniu od tradycyjnych modeli agronomicznych zastosowanie podejścia AI umożliwia modelowanie nieliniowych interakcji między czynnikami siedliska, takimi jak warunki glebowe i klimatyczne, a czynnikami biologicznymi mającymi bezpośredni wpływ na plony roślin. W obszarze technologii cyfrowych wyróżnia się przede wszystkim uczenie maszynowe, głębokie uczenie oraz uczenie ze wzmocnieniem (*reinforcement learning*), które umożliwia agentowi podejmowanie sekwencyjnych decyzji na podstawie informacji zwrotnej pochodzącej ze środowiska i jest coraz częściej wykorzystywane w problemach optymalizacyjnych związanych z zarządzaniem zasobami w roľnictwie¹⁷. Algorytmy takie jak Random Forest, SVM i XGBoost są wykorzystywane do przewidywania wielkości plonów, klasyfikacji typów gleby oraz oceny zapotrzebowania roślin na składniki pokarmowe^{8, 18}. Modele głębokiego uczenia znajdują zastosowanie w analizie danych obrazowych, umożliwiając identyfikację stresów roślinnych i niedoborów składników pokarmowych.

Szczególnie ważne staje się wykorzystanie AI w systemach VRA (*variable rate application*), gdzie zalecenia nawozowe są różnicowane przestrzennie w obrębie pola. Jednocześnie ograniczenia związane z jakością danych i interpretowalnością modeli powodują, że rozwój AI w roľnictwie powinien być łączony z podejściem *explainable AI* (XAI), oznaczającym zbiór metod umożliwiających interpretację działania modeli sztucznej inteligencji oraz identyfikację wpływu poszczególnych zmiennych na uzyskiwane wyniki. W roľnictwie rozwiązania XAI zwiększają przejrzystość rekomendacji nawozowych i umożliwiają ich audytowanie w systemach MRV¹⁹. Szczególnie istotne są najnowsze badania dotyczące ekonomicznej efektywności prognoz opartych na różnych źródłach informacji. Lee i współpr.⁹ wykazali, że opłacalność wykorzystania map cyfrowych w roľnictwie precyzyjnym do stosowania różnych dawek nawozów azotowych w różnych strefach pola, tzw. technologia VRN (*variable rate nitrogen prescriptions*), może być silnie zróżnicowana przestrzennie i sezonowo, a efekt ekonomiczny zaleceń nawozowych

opartych na danych zdalnych względem zaleceń opartych na historii plonów wahał się od strat ekonomicznych do wyraźnych zysków. Autorzy podkreślili, że długoterminowa informacja o reakcji plonu na nawożenie, zapisana w historii plonowania, oraz wczesnowiosenna informacja o stanie ładu, wyrażona m.in. przez NDVI, mają charakter komplementarny. Oznacza to, że efektywne systemy AI w nawożeniu powinny integrować oba typy danych i adaptować decyzje do przebiegu sezonowej zmienności pogodowej.

Efektywność nawożenia

Efektywność wykorzystania azotu NUE (*nitrogen use efficiency*) stanowi jeden z kluczowych wskaźników oceny zrównoważenia systemów rolniczych. NUE definiowana jest zwykle jako stosunek między ilością azotu pobranego przez rośliny a ilością azotu wprowadzonego do systemu^{3,20}. W zależności od podejścia stosuje się także bardziej szczegółowe wskaźniki, takie jak efektywność produkcyjna azotu (*nitrogen recovery efficiency*), efektywność ekonomiczna azotu (*nitrogen agronomic efficiency*) i częściowa produktywność azotu (*partial factor nitrogen productivity*)¹⁵. Niska wartość NUE oznacza jednocześnie mniejszą produktywność ekonomiczną nawożenia i większe ryzyko strat środowiskowych. Szacuje się, że globalnie tylko część azotu aplikowanego do systemu produkcyjnego jest ostatecznie wykorzystywana przez rośliny (ok. 55%), podczas gdy reszta ulega stratom przez wymywanie, ulatnianie lub denitryfikację⁴. Poprawa NUE ma więc kluczowe znaczenie zarówno dla rentowności gospodarstwa, jak i dla ograniczenia eutrofizacji, emisji NH_3 i emisji N_2O . W tym kontekście szczególne znaczenie ma koncepcja zrównoważonego zarządzania składnikami pokarmowymi (*4R nutrient stewardship*), promująca właściwe źródło, właściwą dawkę, właściwy termin i właściwe miejsce aplikacji nawozu²¹. Integracja tej koncepcji z technologiami cyfrowymi i AI stanowi jeden z głównych kierunków rozwoju nowoczesnego nawożenia.

MRV i polityki klimatyczne

Systemy MRV odgrywają coraz większą rolę w politykach klimatycznych, ponieważ umożliwiają wiarygodne monitorowanie, raportowanie i weryfikację emisji oraz efektów działań redukcyjnych i sekwestracyjnych. W rolnictwie ich znaczenie jest szczególnie duże ze względu na złożoność procesów biologicznych, heterogeniczność warunków siedliska oraz trudności w bezpośrednim pomiarze emisji, takich jak N_2O , i zmian w zasobach węgla organicznego gleby²².

Wytyczne IPCC wyróżniają 3 poziomy szczegółowości szacowania emisji: Tier 1, który wykorzystuje domyślne współczynniki emisji publikowane przez IPCC, Tier 2, który opiera się na współczynnikach specyficznych dla kraju lub regionu, i Tier 3, który wykorzystuje zaawansowane modele procesowe lub bezpośrednie pomiary terenowe,

umożliwiając najbardziej precyzyjne oszacowanie emisji. Wdrożenie wyższych poziomów wymaga jednak wykorzystania danych lokalnych i bardziej zaawansowanych modeli²³.

Na poziomie Unii Europejskiej znaczenie systemów MRV rośnie wraz z rozwojem ram certyfikacji działań klimatycznych i środowiskowych. W tym kontekście integracja AI z MRV może zwiększyć dokładność i skalowalność raportowania, zwłaszcza gdy modelowanie emisji jest zasilane danymi z czujników, systemów FMIS (*farm management information systems*) i teledetekcji. Rozwój takich systemów ma kluczowe znaczenie dla rynków środowiskowych, raportowania ESG (*environmental, social and governance*) i rozwoju działań klimatycznych w rolnictwie.

Najnowsze badania wskazują, że rozwój MRV w rolnictwie wymaga nie tylko zaawansowanych modeli, ale również metod ograniczania niepewności międzymodelowej. Basso i współpracownicy²³ wykazali, że zastosowanie wieloczynnikowych modeli MME (*multi-model ensemble*; prognozowanie wielomodelowe) w analizie 46 mln ha gruntów ornych środkowej części Stanów Zjednoczonych w rozdzielczości 4 km² pozwoliło lepiej oszacować zmiany zawartości substancji organicznej gleby i emisji N_2O związane z praktykami regeneratywnymi niż wykorzystanie pojedynczych modeli procesowych. Co ważne, autorzy podkreślili, że prognozowanie MME uzyskało większą dokładność i mniejszą niepewność po walidacji na doświadczeniach długoterminowych, co ma bezpośrednie znaczenie dla projektowania scenariuszy MRV i rynków węglowych.

Drugim istotnym problemem dla MRV pozostaje jakość i porównywalność danych laboratoryjnych, zwłaszcza w odniesieniu do zawartości substancji organicznej gleby. Brinton i współpracownicy²⁴ wskazują, że dla poprawy efektów modelowania niezbędne jest zwiększenie liczby pobieranych próbek oraz zapewnienie jednorodności próbek gleby pobranej z pola uprawnego. Bez takich działań dane zawartości substancji organicznej gleby mogą zniekształcać rzeczywiste różnice między wartościami rzeczywistymi i prognozowanymi z modelu, co ma bezpośrednie znaczenie dla wiarygodności MRV i decyzji podejmowanych w gospodarstwach oraz w programach środowiskowych.

Badania Lee i współpracownicy⁹ pokazują, że recepty oparte na NDVI i historii plonów nie powinny być traktowane jako konkurencyjne, lecz jako uzupełniające się źródła informacji, których przydatność zależy od przebiegu sezonu i utrzymywania się wczesnosezonowych warunków pogodowych. Z kolei Fowler i współpracownicy¹⁴ wskazują, że długoterminowe wzorce plonowania mogą ujawniać atrybuty zdrowotności gleby i stanowić wiarygodną podstawę dla wydzielania stref zarządzania. Oznacza to, że skuteczność systemów AI w nawożeniu zależy nie tylko od algorytmu, ale od jakości architektury danych wejściowych oraz logiki łączenia informacji historycznej i bieżącej.

Z przeglądu literatury wynika także, że poszczególne komponenty zrównoważonego zarządzania składnikami

pokarmowymi na polu, takie jak rolnictwo precyzyjne, modele bilansowe, AI oraz systemy MRV, są intensywnie rozwijane, jednak ich pełna integracja pozostaje nadal ograniczona. Brakuje zwłaszcza modeli łączących optymalizację nawożenia, bilans składników pokarmowych i raportowanie wskaźników środowiskowych w ramach jednego spójnego podejścia analitycznego. Niniejszy artykuł stanowi próbę wypełnienia tej luki.

Część badawcza

Metodyka badań

Koncepcja modelu badawczego

W opracowaniu zaproponowano koncepcję modelu hybrydowego. Proponowana koncepcja modelu badawczego opiera się na integracji podejścia procesowego z metodami sztucznej inteligencji, tworząc hybrydowy system decyzyjny wspierający optymalizację nawożenia mineralnego oraz zarządzanie bilansem składników pokarmowych w rolnictwie precyzyjnym. Hybrydowy charakter modelu polega na połączeniu modeli *data-driven* z modelami procesowymi opisującymi przepływy składników pokarmowych w systemie gleba-roślina-atmosfera.

Model wykorzystuje dane statyczne i dynamiczne pozyskiwane z systemów IoT, stacji meteorologicznych, danych satelitarnych oraz systemów FMIS. Architektura modelu obejmuje moduł akwizycji i przetwarzania danych, moduł analityczny oparty na AI oraz moduł decyzyjny i raportowy zintegrowany z MRV. Centralnym elementem modelu jest wielokryterialna funkcja celu, obejmująca maksymalizację plonu, minimalizację kosztów nawożenia, minimalizację emisji gazów cieplarnianych oraz poprawę NUE. Model ma charakter dynamiczny i umożliwia aktualizację rekomendacji w trakcie sezonu wegetacyjnego.

Proponowana architektura modelu została zaprojektowana w taki sposób, aby łączyć 2 komplementarne typy informacji przestrzennej, czyli informację historyczną, wynikającą z wieloletnich map plonów i stref stabilności plonowania, oraz informację bieżącą, wynikającą z obserwacji łanu w trakcie sezonu wegetacyjnego. Takie podejście znajduje uzasadnienie zarówno w badaniach wskazujących na wartość stref stabilności plonu dla tworzenia map dawek nawozów, jak i w najnowszych analizach ekonomicznych zmiennych prognozowanych dawek azotu (*variable rate nitrogen prescriptions*), które pokazują, że historia plonów i zdalne pomiary łanu wzajemnie się uzupełniają.

Dane wejściowe

Analiza została przeprowadzona w formie modelowego studium przypadku opartego na danych referencyjnych pochodzących z literatury naukowej, danych meteorologicznych, statystyk rolniczych oraz parametrów charakterystycznych dla gospodarstw zlokalizowanych w Europie Środkowej.

Do przeprowadzenia analiz wykorzystano 4 podstawowe kategorie danych wejściowych, czyli dane glebowe, meteorologiczne, teledetekcyjne oraz agronomiczne i operacyjne. Dane meteorologiczne pozyskano z ogólnodostępnych baz meteorologicznych (IMGW-PIB oraz ERA5), dane glebowe opracowano na podstawie charakterystyk glebowych IUNG-PIB, natomiast dane produkcyjne i nawozowe przyjęto na podstawie średnich parametrów gospodarstw specjalizujących się w produkcji zbóż w Polsce.

Podstawowymi danymi glebowymi wprowadzonymi do modelu były: odczyn gleb (pH), zasobność w N oraz przyswajalne formy P i K, zawartość materii organicznej, pojemność wodna i tekstura gleb. Dane meteorologiczne obejmowały temperaturę, opady, promieniowanie słoneczne, wilgotność względną i prędkość wiatru. Jako dane teledetekcyjne wprowadzono wskaźniki NDVI i LAI. Dane agronomiczne dotyczyły rodzaju uprawy, historii plonów, dawek nawozów, terminów i stosowanych technologii ich aplikacji. Uzupełnieniem były dane z czujników IoT mierzących parametry środowiskowe w czasie rzeczywistym. Dane zostały oczyszczone z błędnych wyników, a następnie poddane procesom normalizacji i standaryzacji. Przejrzystość źródeł danych i procedur ich przetwarzania jest szczególnie ważna w kontekście późniejszej integracji z MRV.

W kontekście danych wejściowych szczególne znaczenie przypisano 2 kategoriom informacji, długoterminowym mapom plonów oraz bieżącym wskaźnikom teledetekcyjnym. Długoterminowe wzorce plonowania pozwalają identyfikować strefy stabilności plonów i pośrednio wnioskować o zróżnicowaniu właściwości glebowych, natomiast wskaźniki takie jak NDVI dostarczają informacji o aktualnej kondycji roślin i wczesnosezonowej reakcji łanu.

Uzyskane wyniki badań wskazują, że połączenie tych źródeł danych zwiększa zarówno wartość decyzyjną modeli nawozowych, jak i ich potencjalną opłacalność w praktyce gospodarstwa.

Model AI

Model AI został zaprojektowany jako system hybrydowy łączący algorytmy uczenia maszynowego i głębokiego uczenia z wiedzą agronomiczną oraz elementami modeli procesowych. Architektura obejmowała warstwę predykcyjną, optymalizacyjną i walidacyjną. Warstwa predykcyjna odpowiadała za estymację plonu, pobranie składników pokarmowych, wskaźników efektywności oraz emisji. Wykorzystano w niej modele, takie jak *random forest*, *gradient boosting*, sieci neuronowe oraz konwolucyjne sieci neuronowe (dla danych obrazowych). Warstwa optymalizacyjna modelu służyła do wyznaczania optymalnych dawek nawozów z wykorzystaniem wielokryterialnej funkcji celu (1):

$$f = \max(\text{plon}) - \lambda_1(\text{koszt}) - \lambda_2(\text{emisje}) \quad (1)$$

w której *plon* oznacza przewidywany plon, *koszt* to koszt nawożenia, *emisje* to emisje gazów cieplarnianych, a λ_1 i λ_2 są współczynnikami wagowymi.

Warstwa walidacyjna obejmowała ocenę jakości modelu z użyciem miar statystycznych, takich jak RMSE (średni kwadratowy błąd zmiennej), MAE (średni błąd bezwzględny) i R^2 (współczynnik determinacji). Proces uczenia modelu opierał się na danych historycznych i inżynierii cech. W modelu uwzględniono także komponent *reinforcement learning*, umożliwiający dostosowanie strategii nawożenia w trakcie sezonu. Zastosowanie modelu AI w niniejszym badaniu ma charakter projektowy i modelowy, a przedstawione wyniki należy interpretować jako rezultaty symulacji scenariuszowej, a nie wynik pełnej walidacji polowej na wieloletnim zbiorze obserwacji. Miary RMSE, MAE i R^2 przedstawiono jako planowany zestaw wskaźników oceny jakości modelu w przypadku jego implementacji na rzeczywistych danych.

Model bilansu składników pokarmowych

Model bilansu składników pokarmowych umożliwia ilościowe odwzorowanie przepływów składników, zwłaszcza azotu, fosforu i potasu, w systemie gleba-roślina-atmosfera. Podstawą modelu jest klasyczne równanie (2):

$$\text{Bilans} = \text{Dostarczanie} - \text{Pobranie} \quad (2)$$

W odniesieniu do azotu model przyjmuje postać (3):

$$N_{\text{bilans}} = (N_{\text{fert}} + N_{\text{dep}} + N_{\text{fix}} + N_{\text{min}}) - (N_{\text{uptake}} + N_{\text{leach}} + N_{\text{vol}} + N_{\text{den}}) \quad (3)$$

w której N_{fert} oznacza azot dostarczony w nawozach mineralnych i organicznych, N_{dep} depozycję atmosferyczną azotu, N_{fix} biologiczne wiązanie azotu, N_{min} azot uwolniony w procesie mineralizacji materii organicznej, N_{uptake} azot pobrany przez rośliny, N_{leach} straty azotu wskutek wymywania, N_{vol} straty azotu wskutek ulatniania, a N_{den} straty azotu w procesie denitryfikacji.

Model bilansu został zintegrowany z modułem AI, co umożliwiło dynamiczną estymację trudno mierzalnych komponentów bilansu oraz lepsze odwzorowanie lokalnych warunków środowiskowych. Należy zwrócić uwagę, że bilans azotu pełni w prezentowanej analizie kluczową funkcję, ponieważ stanowi podstawę oceny zarówno efektywności nawożenia, jak i potencjalnych strat środowiskowych.

Integracja AI + MRV

Integracja AI z systemami MRV stanowiła kluczowy element proponowanego modelu. Architektura integracji obejmowała warstwę monitoringu, warstwę analityczno-predykcijną oraz warstwę raportowania i weryfikacji. Warstwa monitoringu odpowiadała za pozyskiwanie danych środowiskowych i operacyjnych z czujników IoT, stacji meteorologicznych, danych satelitarnych i systemów FMIS. Warstwa analityczna wykorzystywała modele AI do estymacji emisji, NUE oraz bilansu składników pokarmowych. Warstwa raportowania i weryfikacji odpowiadała zaś za

agregację wyników oraz ich przygotowanie do wykorzystania w procesach certyfikacyjnych i raportowych. Podejście to pozwoliło na przejście od uproszczonych współczynników emisji do bardziej zaawansowanych, lokalnych modeli predykcyjnych. Jednocześnie należy podkreślić, że przedstawiona architektura integracji modeli ma charakter koncepcyjny i wymaga dalszej walidacji operacyjnej w warunkach rzeczywistych.

Z punktu widzenia architektury MRV ważne jest również ograniczanie niepewności wynikającej z zastosowania pojedynczego modelu. Najnowsze badania wskazują, że modelowanie MME może poprawiać dokładność i zmniejszać niepewność szacowania zmian zawartości substancji organicznej w glebie i emisji N_2O względem pojedynczych modeli plonowych, zwłaszcza w analizach wielkoskalowych i zróżnicowanych warunkach glebowo-klimatycznych. Oznacza to, że integracja AI z MRV powinna być rozumiana nie tylko jako zastępowanie prostych współczynników bardziej zaawansowaną analityką, lecz także jako budowa architektury zdolnej do łączenia wielu źródeł danych, wielu modeli i procedur walidacyjnych.

Metody analityczne

Operacjonalizacja pytań badawczych i sposób oceny hipotez

Na potrzeby części analitycznej przyjęto następujące hipotezy robocze: (i) H1. Zastosowanie modelu AI w zarządzaniu nawożeniem prowadzi do wzrostu wskaźnika efektywności wykorzystania azotu (NUE) względem scenariusza bazowego; (ii) H2. Zastosowanie modelu AI prowadzi do obniżenia nadwyżki bilansu azotu oraz zmniejszenia emisji N_2O względem scenariusza bazowego; (iii) H3. Integracja AI z architekturą MRV zwiększa zdolność do monitorowania, raportowania i weryfikacji efektów środowiskowych działań nawozowych.

W celu zapewnienia przejrzystości metodologicznej przeprowadzono operacjonalizację zmiennych wykorzystywanych do oceny hipotez (tabela 1). Dla hipotezy H1 zmienną zależną był wskaźnik NUE liczony jako stosunek ilości azotu pobranego przez rośliny do ilości azotu zastosowanego w nawozach mineralnych. Dla hipotezy H2 zmiennymi zależnymi były bilans azotu wyrażony w kg N/ha oraz emisje podtlenku azotu (N_2O) przeliczone na ekwiwalent ditlenku węgla (CO_2e). W przypadku hipotezy H3 oceniano zdolność systemu do monitorowania, raportowania i weryfikacji danych środowiskowych poprzez analizę kompletności danych, możliwości śledzenia źródeł danych, przejrzystości procedur raportowania oraz audytowalności wyników.

Weryfikacja hipotez została przeprowadzona w formie modelowego studium przypadku poprzez porównanie scenariusza bazowego BAU (*business as usual*) z wariantem wykorzystującym sztuczną inteligencję oraz technologię zmiennego dawkowania nawozów VRA (*variable rate*

Table 1. Operationalization of research questions and hypotheses

Tabela 1. Operacjonalizacja pytań badawczych i hipotez

Pytanie/hipoteza	Zmienna/obiekt oceny	Miara	Sposób porównania
P1/H1	efektywność nawożenia	NUE = N pobrany przez rośliny/N zastosowany w nawozach	BAU vs. AI + VRA
P2/H2	bilans azotu	kg N/ha	BAU vs. AI + VRA
P2/H2	emisje podtlenku azotu	N ₂ O, CO ₂ e/ha	BAU vs. AI + VRA
P3/H3	jakość MRV	kompletność danych, śledzenie źródeł, przejrzystość, audytowalność	ocena architektury systemu

BAU – scenariusz bazowy oparty na standardowych praktykach nawozowych; AI + VRA – scenariusz wykorzystujący sztuczną inteligencję oraz technologię zmiennego dawkowania nawozów; na potrzeby modelu przyjęto, że w scenariuszu BAU średni plon pszenicy ozimej wynosił 7,8 t/ha, uwzględniając nawożenie na poziomie 180 kg N/ha; w scenariuszu AI + VRA prognozowany plon wynosił 8,3–8,6 t/ha, co odpowiada wzrostowi o 6–10%; wartości mają charakter modelowy i stanowią wynik symulacji scenariuszowej dla gospodarstw reprezentatywnych dla warunków Europy Środkowej

application). Należy podkreślić, że badanie nie miało charakteru eksperymentu terenowego ani klasycznego badania statystycznego. Weryfikacja hipotez została przeprowadzona na poziomie analizy scenariuszowej, a uzyskane wyniki należy interpretować jako rezultaty modelowania służące ocenie potencjalnego wpływu zastosowania AI na efektywność nawożenia, bilans składników pokarmowych oraz funkcjonowanie systemów MRV.

Wartości wskaźnika NUE przekraczające poziom 1,0 nie oznaczają błędu obliczeniowego, lecz mogą występować w warunkach rzeczywistych, gdy całkowite pobranie azotu przez rośliny przewyższa ilość azotu zastosowanego w nawozach mineralnych. Wynika to z faktu, że rośliny wykorzystują nie tylko azot pochodzący z bieżącego nawożenia, ale również azot uwalniany w procesie mineralizacji materii organicznej gleby, azot pochodzący z depozycji atmosferycznej oraz pozostałości azotu zgromadzonego w glebie po nawożeniu prowadzonym w poprzednich sezonach. W analizowanym modelu wartości NUE na poziomie 0,92–1,01 należy interpretować jako efekt bardziej efektywnego wykorzystania całkowitych zasobów azotu dostępnych w systemie gleba-roślina, a nie wyłącznie azotu dostarczonego w bieżącym roku w nawozach mineralnych.

Studium przypadku (analiza empiryczna o charakterze modelowym)

Charakterystyka obszaru badawczego

Analizę przeprowadzono dla modelowego gospodarstwa rolnego reprezentatywnego dla intensywnej produkcji zbóż w warunkach klimatycznych Europy Środkowej. Gospodarstwo obejmowało ok. 120 ha gruntów ornych, a dominującą uprawą była pszenica ozima. Gleby należały głównie do gleb brunatnych i płowych, charakteryzujących się zawartością materii organicznej na poziomie 1,5–2,2%

Table 2. Comparison of BAU and AI + VRA scenarios

Tabela 2. Porównanie scenariuszy BAU i AI + VRA

Wskaźnik	BAU	AI	Zmiana, %
Dawka, kg N/ha	180	145–155	od -14 do -19
NUE	0,72	0,92–1,01	28–40
Plon pszenicy ozimej, t/ha	7,8	8,3–8,6	6–10
Pobranie azotu przez rośliny, kg N/ha	130	143–147	10–13
Emisje N ₂ O, %	100	80–88	od -12 do -20
Emisje CO ₂ e, t CO ₂ e/(ha·r)	poziom bazowy	od -0,3 do -0,6	spadek
Bilans azotu, kg N/ha	40–60	10–20	spadek nadwyżki

oraz zróżnicowaną teksturą. Warunki klimatyczne odpowiadały obszarom o średniej rocznej temperaturze 8–10°C i sumie opadów 550–650 mm.

Powierzchnię 120 ha przyjęto jako reprezentatywną dla średnich i większych gospodarstw towarowych prowadzących intensywną produkcję zbóż w Europie Środkowej, dla których wdrożenie technologii rolnictwa precyzyjnego jest ekonomicznie uzasadnione.

Należy podkreślić, że studium przypadku ma charakter modelowy i ilustracyjny. Jego celem jest przedstawienie logiki działania proponowanego modelu oraz potencjalnych efektów wdrożenia AI w zarządzaniu nawożeniem, a nie prezentacja wyników pełnoskalowego eksperymentu terenowego.

Dane i założenia modelowe

Analizę oparto na danych wieloźródłowych obejmujących informacje glebowe, meteorologiczne, teledetekcyjne oraz operacyjne. Przyjęto 2 scenariusze: scenariusz bazowy (BAU) (jednolite nawożenie azotowe na poziomie 180 kg N/ha, brak uwzględnienia zmienności przestrzennej pola i decyzje nawozowe oparte na standardowych zaleceniach agronomicznych) oraz scenariusz AI + VRA (zmienne dawkowanie nawozów (*variable rate application*), optymalizacja dawek nawozowych na poziomie subparceli o powierzchni 0,5–1 ha i wykorzystanie modeli AI do prognozowania potrzeb nawozowych roślin).

Do szacowania emisji zastosowano podejście zgodne z metodyką IPCC²⁾. Jako punkt wyjścia wykorzystano współczynniki emisji Tier 1, które następnie skorygowano na podstawie lokalnych danych dotyczących gleby, warunków pogodowych oraz praktyk nawozowych. Takie podejście odpowiada logice metod Tier 2 i Tier 3, wykorzystujących dane regionalne i modelowanie procesowe w celu zwiększenia dokładności szacowania emisji. Wszystkie wartości liczbowe wykorzystane w studium przypadku mają charakter referencyjny i zostały przyjęte na podstawie danych literaturowych oraz parametrów typowych dla gospodarstw prowadzących intensywną produkcję zbóż w warunkach Europy Środkowej.

Wyniki analizy

Uzyskane wyniki należy interpretować jako rezultaty modelowania scenariuszowego (tabela 2). Analiza wskazuje, że średnia dawka nawożenia azotowego może zostać ograniczona z poziomu 180 do 145–155 kg N/ha, co odpowiada zmniejszeniu zużycia nawozów o 14–19%. Jednocześnie model prognozuje wzrost plonów o 6–10%, wynikający z lepszego dopasowania dawek nawozowych do lokalnych warunków glebowych i aktualnych potrzeb roślin.

Zakładając pobranie azotu przez rośliny na poziomie ok. 130 kg N/ha w scenariuszu BAU oraz 143–147 kg N/ha w scenariuszu AI + VRA, wskaźnik NUE wzrasta z ok. 0,72 do 0,92–1,01, co odpowiada poprawie efektywności wykorzystania azotu o 28–40%.

Model wskazuje również na zmniejszenie emisji N_2O o 12–20%, co odpowiada ograniczeniu emisji o 0,3–0,6 t CO_2e /ha rocznie. Nadwyżka bilansu azotu zmniejsza się z poziomu 40–60 kg N/ha do 10–20 kg N/ha.

Podstawowym wskaźnikiem ekonomicznym poddanym analizie był zwrot z inwestycji (ROI). Uwzględniono zarówno koszty wdrożenia technologii AI i VRA, jak i korzyści wynikające ze zmniejszenia zużycia nawozów oraz wzrostu plonów.

Przyjęto koszt wdrożenia systemu AI i VRA na poziomie 50–120 euro/ha (ok. 215–516 zł/ha, uwzględniając kurs 1 euro = 4,30 zł) oraz koszty operacyjne wynoszące 10–20 euro/ha rocznie (43–86 zł/ha). Korzyści obejmowały oszczędności nawozowe rzędu 40–80 euro/ha rocznie (172–344 zł/ha) oraz wzrost wartości produkcji o 70–150 euro/ha rocznie (301–645 zł/ha).

Łączny dodatni efekt ekonomiczny oszacowano na poziomie 80–180 euro/ha rocznie, co odpowiada 344–774 zł/ha rocznie. Orientacyjny okres zwrotu inwestycji wyniósł 2–4 lat. Powyższe wartości mają charakter scenariuszowy i powinny być traktowane jako ilustracja potencjalnych korzyści ekonomicznych wynikających z wdrożenia technologii AI w rolnictwie precyzyjnym.

Omówienie wyników

Przeprowadzone modelowanie scenariuszowe wskazuje, że integracja sztucznej inteligencji z technologiami rolnictwa precyzyjnego oraz architekturą MRV może prowadzić do jednoczesnej poprawy efektywności produkcyjnej, ekonomicznej i środowiskowej gospodarstw rolnych. W analizowanym przypadku zastosowanie modeli AI wspierających zmienne dawkowanie nawozów (VRA) pozwoliło na ograniczenie zużycia nawozów azotowych o 14–19%, zapewniając równoległy wzrost plonów o 6–10% oraz poprawę wskaźnika efektywności wykorzystania azotu (NUE) o 28–40%.

Szczególnie istotnym rezultatem jest ograniczenie nadwyżki bilansu azotu z poziomu 40–60 kg N/ha do poziomu 10–20 kg N/ha. Nadwyżki azotu są bowiem jednym z głównych źródeł strat składników pokarmowych do środowiska, odpowiadając za zwiększone ryzyko wymywania azotanów do wód gruntowych i powierzchniowych oraz emisji pod-

tlenku azotu (N_2O). Uzyskane wyniki wskazują również na możliwość zmniejszenia emisji N_2O o 12–20%, co odpowiada ograniczeniu emisji o 0,3–0,6 t CO_2e /ha rocznie.

Uzyskane rezultaty pozostają zgodne z kierunkiem wniosków prezentowanych w literaturze przedmiotu, zgodnie z którym rolnictwo precyzyjne, analiza danych oraz technologie cyfrowe przyczyniają się do poprawy efektywności wykorzystania zasobów produkcyjnych i ograniczenia presji środowiskowej^{7, 13}. Wyniki są również spójne z najnowszymi badaniami dotyczącymi ekonomicznej efektywności technologii VRN, wskazującymi na znaczenie integracji danych historycznych o plonach z bieżącymi danymi teledetekcyjnymi i meteorologicznymi w procesie podejmowania decyzji nawozowych^{9, 14}.

Jednocześnie należy podkreślić, że przedstawiona analiza ma charakter modelowy i nie zastępuje pełnej walidacji terenowej. Wyniki należy interpretować jako naukowo uzasadnioną ilustrację potencjału proponowanego podejścia, a nie jako bezpośredni dowód jego skuteczności w konkretnych warunkach gospodarstwa. Ostateczna ocena efektywności modelu wymaga przeprowadzenia badań polowych obejmujących wiele sezonów wegetacyjnych i zróżnicowane warunki agroekologiczne.

Znaczenie przeprowadzonych badań dla MRV i polityki klimatycznych

Uzyskane wyniki wskazują, że sztuczna inteligencja może stać się istotnym elementem nowoczesnych systemów monitorowania, raportowania i weryfikacji (MRV) stosowanych w rolnictwie. Integracja danych glebowych, meteorologicznych, teledetekcyjnych oraz operacyjnych z modelami AI umożliwia bardziej precyzyjne szacowanie efektów środowiskowych związanych z nawożeniem, w tym zmian bilansu azotu oraz emisji gazów cieplarnianych.

Ma to szczególne znaczenie w kontekście rozwoju europejskich i międzynarodowych systemów raportowania środowiskowego, polityki klimatycznej oraz nowych mechanizmów wsparcia dla rolnictwa zrównoważonego. Poprawa efektywności nawożenia, zmniejszenie emisji oraz ograniczenie strat składników pokarmowych mogą w przyszłości stanowić podstawę funkcjonowania programów wsparcia, systemów płatności za usługi ekosystemowe, praktyk rolnictwa regeneratywnego oraz mechanizmów certyfikacji efektów środowiskowych.

Jednocześnie praktyczne wykorzystanie takich rozwiązań wymaga dalszego rozwoju procedur walidacyjnych, metod ograniczania niepewności modeli oraz standaryzacji zasad raportowania i audytu danych wykorzystywanych w systemach MRV.

Ograniczenia badania

Opracowanie ma charakter hybrydowy i łączy przegląd literatury, model koncepcyjny oraz modelowe studium

przypadku. Chociaż przedstawione podejście opiera się na aktualnym stanie wiedzy naukowej oraz uznanych metodach modelowania procesów rolniczych, nie stanowi ono pełnego eksperymentu terenowego prowadzonego na wieloletnim zbiorze obserwacji.

Do głównych ograniczeń badania należy zaliczyć brak bezpośrednich pomiarów emisji N_2O w warunkach polowych, brak walidacji modelu na danych pochodzących z wielu gospodarstw, brak inferencyjnej analizy statystycznej opartej na rzeczywistych obserwacjach oraz zależność wyników od przyjętych założeń scenariuszowych. Ograniczeniem pozostaje również konieczność lokalnej kalibracji modeli AI i modeli bilansowych, wynikająca z dużego zróżnicowania warunków glebowych, klimatycznych i technologicznych występujących w rolnictwie. Ograniczenia te nie podważają wartości przedstawionego modelu koncepcyjnego, wskazują jednak obszary wymagające dalszej weryfikacji empirycznej.

Wnioski i kierunki dalszych badań

Przeprowadzona analiza teoretyczna i modelowa wskazuje, że integracja sztucznej inteligencji z modelami bilansu składników pokarmowych oraz technologiami rolnictwa precyzyjnego stanowi perspektywiczny kierunek rozwoju nowoczesnych systemów produkcji rolnej. Uzyskane wyniki sugerują, że wykorzystanie AI może przyczyniać się do poprawy efektywności wykorzystania azotu, ograniczenia nadwyżek bilansu składników pokarmowych, zmniejszenia emisji gazów cieplarnianych oraz wzrostu rentowności gospodarstw.

Przedstawiony model pokazuje możliwość osiągnięcia synergii między celami produkcyjnymi i środowiskowymi. Ograniczenie dawek nawozowych nie musi prowadzić do obniżenia plonów, jeżeli decyzje nawozowe są podejmowane na podstawie kompleksowej analizy danych, uwzględniającej zmienność przestrzenną pola, aktualny stan roślin oraz warunki pogodowe. Integracja modeli AI z modelami bilansowymi umożliwi bardziej realistyczne odwzorowanie procesów zachodzących w układzie gleba-roślina-atmosfera, natomiast połączenie tych rozwiązań z architekturą MRV zwiększa potencjał monitorowania i raportowania efektów środowiskowych.

Przeprowadzona analiza ekonomiczna wskazuje również, że wdrożenie rozwiązań opartych na AI i VRA może być uzasadnione ekonomicznie, generując dodatkowe korzyści finansowe wynikające zarówno z ograniczenia zużycia nawozów, jak i poprawy produktywności upraw.

Pomimo obiecujących rezultatów przedstawione wnioski wymagają dalszej weryfikacji empirycznej. Przyszłe

badania powinny koncentrować się na wieloletnich doświadczeniach polowych prowadzonych w różnych warunkach agroekologicznych, walidacji modeli AI na rzeczywistych danych produkcyjnych oraz integracji modeli nawożenia z zaawansowanymi systemami MRV. Szczególnie istotnym kierunkiem rozwoju będzie wykorzystanie technologii IoT, danych satelitarnych wysokiej rozdzielczości, cyfrowych bliźniaków gospodarstw oraz metod wielomodelowych ograniczających niepewność prognoz środowiskowych.

Równolegle konieczne jest pogłębienie badań nad społecznymi i ekonomicznymi uwarunkowaniami wdrażania technologii cyfrowych w rolnictwie, w tym dostępnością technologii, kompetencjami cyfrowymi użytkowników, interoperacyjnością systemów oraz zagadnieniami związanymi z własnością i bezpieczeństwem danych. To właśnie te czynniki mogą w najbliższych latach decydować o skali i tempie wykorzystania sztucznej inteligencji w rolnictwie precyzyjnym.

Otrzymano: 03-07-2026

Zrecenzowano: 13-07-2026

Zaakceptowano: 24-07-2026

Opublikowano: 18-08-2026

LITERATURA

- [1] FAO, *The future of food and agriculture*, Food and Agriculture Organization of the United Nations, Rzym 2022.
- [2] IPCC, *2019 Refinement to the 2006 IPCC guidelines for national greenhouse gas inventories*, IPCC, Genewa 2019.
- [3] K.G. Cassman, A. Dobermann, D.T. Walters, *Ambio* 2002, **31**, nr 2, 132.
- [4] X. Zhang, E.A. Davidson, D.L. Mauzerall i in., *Nature* 2015, **528**, nr 7580, 190.
- [5] J.N. Galloway, A.R. Townsend, J.W. Erisman i in., *Science* 2008, **320**, nr 5878, 889.
- [6] S. Wolfert, L. Ge, C. Verdouw, M.J. Bogaardt, *Agric. Syst.* 2017, **153**, 69.
- [7] B. Basso, J. Antle, *Nat. Sustain.* 2020, **3**, 230.
- [8] K.G. Liakos, P. Busato, D. Moshou, S. Pearson, D. Bochtis, *Sensors* 2018, **18**, nr 8, 2674.
- [9] S.W. Lee, S.M. Swinton, B. Basso, *Precis. Agric.* 2025, **26**, nr 4, 58.
- [10] J.W. Jones, G. Hoogenboom, C.H. Porter i in., *Eur. J. Agron.* 2003, **18**, 235.
- [11] B. Basso, B. Dumont, D. Cammarano, A. Pezzuolo, F. Marinello, L. Sartori, *Sci. Total Environ.* 2016, **545-546**, 227.
- [12] D.J. Mulla, *Biosyst. Eng.* 2013, **114**, nr 4, 358.
- [13] R. Gebbers, V.I. Adamchuk, *Science* 2010, **327**, nr 5967, 828.
- [14] A. Fowler, B. Basso, F. Maureira, N. Millar, R. Ulbrich, W.F. Brinton, *Sci. Rep.* 2024, **14**, 465.
- [15] A. Dobermann, [w:] *Fertilizer Best Management Practices*, IFIA, Bruksela 2007.
- [16] D.P. Holzworth, N.I. Huth, P.G. de Voili i in., *Environ. Modell. Softw.* 2014, **62**, 327.
- [17] R.S. Sutton, A.G. Barto, *Reinforcement learning. An introduction*, MIT Press, Cambridge 1998.
- [18] A. Kamilaris, F.X. Prenafeta-Boldú, *Comput. Electron. Agric.* 2018, **147**, 1.
- [19] C. Rudin, *Nat. Mach. Intell.* 2019, **1**, nr 5, 206.
- [20] W.R. Raun, G.V. Johnson, *Agron. J.* 2019, **91**, 357.
- [21] P. Fixen, F. Brentrup, T. Bruulsema, F. Garcia, R. Norton, S. Zingore, [w:] *Managing water and fertilizer for sustainable agricultural intensification* (red. P. Drechsel, H. Heffer, R. Magen, D.W. Mikkelsen), IFA, IWMI, IPNI, IPI, Paryż 2015.
- [22] K. Paustian, J. Lehmann, S. Ogle, D. Reay, G.P. Robertson, P. Smith, *Nature* 2016, **532**, nr 7597, 49.
- [23] B. Basso, T. Tadiello, N. Millar, G.P. Robertson, K. Paustian, A. Ruane, C.O. Stöckle, Y. Zhang i in., *Sci. Rep.* 2025, **15**, 24881.
- [24] W. Brinton, B. Basso, N. Millar, K. Covey, C. Bettigole, S. Jagadamma, F. Loeffler, S. Kolodney, *Agron. J.* 2025, **117**, e70018.