

Zagadnienia Doradztwa Rolniczego

2'24⁽¹¹⁶⁾



CENTRUM DORADZTWA
ROLNICZEGO W BRWINOWIE



STOWARZYSZENIE EKONOMISTÓW
ROLNICTWA I AGROBIZNESU

30 lat
Zagadnień
Doradztwa
Rolniczego

Zagadnienia Doradztwa Rolniczego

KWARTALNIK

2'24⁽¹¹⁶⁾

CENTRUM DORADZTWA ROLNICZEGO W BRWINOWIE
STOWARZYSZENIE EKONOMISTÓW ROLNICTWA I AGROBIZNESU



LITERATURA

1. Lejk-Kępa, A. (2003). Analiza funkcjonowania rolniczego ubezpieczenia społecznego, *Emerytury i renty w liczbach*, nr 20. Ubezpieczenie w Rolnictwie, Warszawa.
2. Obidziński, S. (1989). Emerytury rolnicze, Fakty i Opinie. Warszawa: IRWiR.
3. Świdorski, J. (1987). System emerytalny w indywidualnej gospodarce chłopskiej, Warszawa: ANS.
4. Wawrzyniak. B., Wojtasik. B. (2005). Ewolucja systemu ubezpieczeń społecznych w rolnictwie, *Wieś i Rolnictwo*, nr 1.
5. Ustawa z dnia 28 czerwca 1962 r. o przejmowaniu niektórych nieruchomości rolnych w zagospodarowanie lub na własność Państwa oraz o zaopatrzeniu emerytalnym właścicieli tych nieruchomości i ich rodzin.
6. Ustawa z dnia 24 stycznia 1968 r. o rentach i innych świadczeniach dla rolników przekazujących nieruchomości rolne na własność Państwa.
7. Ustawa z dnia 29 maja 1974 r. o przekazywaniu gospodarstw rolnych na własność Państwa za rentę i spłaty pieniężne.
8. Ustawa z dnia 27 października 1977 r. o zaopatrzeniu emerytalnym oraz innych świadczeniach dla rolników i ich rodzin.
9. Ustawa z dnia 14 grudnia 1982 r. o ubezpieczeniu społecznym rolników indywidualnych i członków ich rodzin.
10. Ustawa z dnia 20 grudnia 1990 r. o ubezpieczeniu społecznym rolników.

Przesłano: 18-12-2023

Zaakceptowano do druku: 25-06-2024



ANALIZA SYSTEMU TELEDIS W OCENIE ZDROWOTNOŚCI ZBÓŻ

Wiesław Golka¹, Magdalena Szechyńska-Hebda², Adrian Golka³,
Jolanta Kowalska⁴, Tomasz Góral⁵, Aleksander Bomberski⁶

Abstrakt: Sztuczne sieci neuronowe (SSN) odgrywają ważną rolę w ocenie stanu zdrowia zbóż we współczesnym rolnictwie. System i aplikacja Teledis wykorzystują obrazowanie RGB upraw zbóż (pszenicy i pszenżyta) oraz SSN, w szczególności konwolucyjne sieci neuronowe (CNN), w celu dokładnej i skutecznej diagnozy różnych chorób roślin. SSN są szkolone na oznakowanych wzorcach, ucząc się rozpoznawać cechy barwne i kształty, wskazujące na zdrowe i porażone rośliny zbożowe. Po przeszkoleniu SSN będą wykorzystane do diagnostyki w warunkach polowych w celu oceny stanu upraw zbóż w czasie niemal rzeczywistym. W niniejszym artykule prezentujemy wyniki badań i analizę precyzji diagnozowania chorób pszenicy ozimej z wykorzystaniem modelu SSN. Skuteczność diagnoz SSN wyniosła 93%, co jest wynikiem zadowalającym, biorąc pod uwagę wczesny etap rozwoju systemu Teledis. System wymaga jeszcze pewnych udoskonaleń, na które zwrócono uwagę w artykule. Integracja SSN z oceną zdrowia zbóż przyczynia się do rozwoju rolnictwa precyzyjnego i ulepszonych praktyk zarządzania uprawami, dlatego przedstawiono również przyszłe kierunki potencjalnego zastosowania systemu Teledis.

Słowa kluczowe: sztuczna sieć neuronowa, choroby roślin, diagnozowanie zbóż

JEL: O36

¹ Actuario, sp. z o.o. w Warszawie (Actuario, sp. z o.o. in Warsaw) | wkład pracy (work input): 30% | e-mail: golkaw@o2.pl

² Instytut Botaniki PAN w Krakowie (Institute of Botany Polish Academy of Sciences in Cracow) | wkład pracy (work input): 30% | ORCID: 0000-0002-6041-6521 | e-mail: szechynska@wp.pl

³ Actuario, sp. z o.o. w Warszawie (Actuario, sp. z o.o. in Warsaw) | wkład pracy (work input): 10%

⁴ Instytut Ochrony Roślin PAN (Institute of Plant Protection – National Research Institute) | wkład pracy (work input): 10% | ORCID: 0000-0002-0588-7355

⁵ Instytut Hodowli i Aklimatyzacji Roślin PAN (Plant Breeding and Acclimatization Institute (IHAR) – National Research Institute) | wkład pracy (work input): 10% | ORCID: 0000-0001-9130-6109

⁶ Centrum Doradztwa Rolniczego w Brwinowie, Wyższa Szkoła Gospodarki w Bydgoszczy (Agricultural Advisory Center in Brwinów, Bydgoszcz University Enterprise of Knowledge) | wkład pracy (work input): 10% | ORCID: 0000-0001-7757-924X | e-mail: a.bomberski@cdr.gov.pl

ANALYSIS OF THE TELEDIS SYSTEM IN HEALTH ASSESSMENT

Wiesław Golka¹, Magdalena Szechyńska-Hebda², Adrian Golka³,
Jolanta Kowalska⁴, Tomasz Góral⁵, Aleksander Bomberski⁶

Abstract: Artificial neural networks (ANNs) play a pivotal role in assessing the health of cereals in modern agriculture. The Teledis system and application employ the RGB imaging of cereal crops (wheat and triticale) and ANNs, particularly convolutional neural networks (CNNs), for accurate and efficient diagnosis of different plant diseases. The neural networks are trained on labeled datasets, learning to recognize color patterns and shape features indicative of healthy and diseased cereals. Once trained, the neural networks are deployed in the field to assess the health of cereal crops in nearly real-time. The technology with ANN has some disadvantages explained in this article. The integration of ANNs in cereal health assessment contributes to precision farming and improved crop management practices in agriculture, therefore future directions of the Teledis system potential application are also provided.

Keywords: artificial neural network, plant diseases, cereal diagnosis

JEL Classification: O36

1. Sztuczne sieci neuronowe w rolnictwie

Świat cyfrowych technologii rozwija się w szybkim tempie, napędzany innowacjami i przyspieszoną komunikacją. Historycznie świat cyfrowy kształtowało kilka kluczowych trendów:

- a) sztuczna inteligencja (SSN) i uczenie maszynowe (ML);
- b) technologia 5G;
- c) internet rzeczy (IoT);
- d) cyberbezpieczeństwo;
- e) rzeczywistość rozszerzona (AR) i rzeczywistość wirtualna (VR);
- f) przetwarzanie w chmurze;
- g) transformacja cyfrowa.

Obecnie rozwój powyższych technologii często postrzegany jest jako niekontrolowany i zagrażający autonomii i wolności człowieka. Bartlett (2019) stwierdził nawet, że albo (cyt.): „*demokracja dogoni cyfrową zmianę, a odpowiedzialne społeczeństwo w porę wykształci obywatelskie nawyki na miarę nowej epoki, albo czekają nas rządy technokratycznych despotów*”.

Człowiek tworzy coraz doskonalsze modele sztucznych sieci neuronowych (SSN) dla zastosowań w coraz większej przestrzeni naszego życia gospodarczego i społecznego. Wdrażanie SNN związane jest zarówno z korzyściami dla społeczeństwa (np. zwiększenie automatyzacji, wydajności, produktywności, optyma-

lizacji procesów, obniżanie kosztów; poprawa ogólnej efektywności operacyjnej; pomoc w identyfikacji potencjalnych zagrożeń i prognozowaniu trendów rynkowych), jak również z niebezpieczeństwem (np. względy etyczne, prywatność danych; błędne przewidywania modeli; zgodność z przepisami; kwestie odpowiedzialności; ataki kontryktoryjne; redakcja zatrudnienia).

W rolnictwie, SSN również wprowadzone zostały prawie we wszystkich obszarach działalności, przyczyniając się do poprawy wydajności, efektywności i zrównoważonego rozwoju gospodarki rolnej:

- a) SSN mogą analizować różne czynniki, takie jak warunki pogodowe, jakość gleby i dane historyczne dotyczące plonów, aby możliwa była predykcja plonów. Informacje te pomagają rolnikom podejmować świadome decyzje dotyczące sadzenia, alokacji zasobów i strategii marketingowych (Niedbała i in., 2005; Stathakis, 2010; Barwicki i in., 2020).
- b) SSN można szkolić na podstawie danych obrazowych w celu wykrywania oznak chorób roślin uprawnych w liściach lub owocach. Analizując wzorce wizualne, SSN mogą zapewnić wczesne wykrywanie chorób, umożliwiając rolnikom podjęcie środków zapobiegawczych i ograniczenie strat w plonach (Delwiche i in., 2019; Qiu i in., 2019; Akerman i in., 2022; Golka i in., 2023).
- c) SSN można zastosować w systemach rozpoznawania obrazu w celu rozróżnienia roślin uprawnych i chwastów. Znajduje to zastosowanie w rolnictwie precyzyjnym, umożliwiając ukierunkowane stosowanie herbicydów, zmniejszając potrzebę nadmiernego stosowania środków chemicznych i minimalizując ich wpływ środków na środowisko naturalne (Chaaro i Martínez, 2020; Monteiro i in., 2021).
- d) SSN mogą analizować dane z różnych źródeł, takich jak zdjęcia satelitarne, czujniki i drony, w celu optymalizacji zarządzania zasobami. Pozwala to na precyzyjne stosowanie wody, nawozów i prowadzi do zwiększenia plonowania przy zmniejszonej presji na środowisko (Kamyab i in., 2023).
- e) SSN mogą przetwarzać historyczne dane klimatyczne w celu przewidywania przyszłych wzorców pogodowych. Informacje te są cenne dla rolników, którzy chcą dostosować dotychczasowe praktyki, wybrać odpowiednie uprawy i wdrożyć strategie zapewniające maksymalizację plonu w obliczu zmieniających się warunków pogodowych i środowiskowych (Fente i Kumar Singh, 2018; Bi i in., 2023).
- f) SSN mogą analizować dane dotyczące stanu gleby, w tym skład i poziom składników odżywczych, w celu oceny stanu podłoża. Informacje te pomagają w wyborze typu upraw, intensywności nawożenia i strategii nawadniania dla zapewnienia zrównoważonych praktyk rolniczych (Ayoubi i in., 2011).

- g) SSN można wykorzystywać do analizowania danych z czujników i urządzeń monitorujących w celu określenia zdrowia, zachowania i produktywności zwierząt gospodarskich. Pomaga to rolnikom w podejmowaniu decyzji związanych z żywieniem, hodowlą i zapobieganiu chorobom (Aguilar-Lazcano i in., 2023).
- h) SSN mogą analizować historyczne dane rynkowe, w tym czynniki podaży i popytu, aby przewidzieć przyszłe ceny towarów i produktów rolnych. Rolnicy mogą wykorzystać te informacje do podejmowania świadomych decyzji o tym, kiedy i gdzie można sprzedać produkty, aby uzyskać maksymalny zysk (Punia i Shankar, 2022).
- i) SSN mogą optymalizować alokację zasobów, takich jak woda, energia i siła robocza, w oparciu o dane w czasie rzeczywistym. Pomaga to w ograniczeniu ilości odpadów, poprawie efektywności wykorzystania zasobów i ostatecznie zwiększeniu ogólnego zrównoważonego charakteru praktyk rolniczych (Chen i in., 2023).
- j) SSN mogą służyć jako systemy wspomagania decyzji, analizując złożone zbiory danych i dostarczając zaleceń dotyczących strategii kompleksowego zarządzania uprawami wielkoobszarowymi (Zhai i in., 2020).
- k) SSN mogą służyć jako systemy wspomagania kontroli jakości i żywności i produktów rolniczych np. defektów, zanieczyszczeń, prawdopodobieństwa zepsucia się, optymalizacji warunków bezpiecznego przechowywania (Łabańska, 2021; Kadir, 2015).

Integracja SSN w rolnictwie przyczynia się zatem do rozwoju inteligentnych praktyk rolniczych, które umożliwiają bardziej precyzyjne i zrównoważone zarządzanie działalnością i gospodarką rolniczą. Jednak istnieje niebezpieczeństwo, że rolnicy, którzy nie będą podążać za technologiami cyfrowymi, będą marginalizowani.

2. Cel i zakres opracowania

Niniejszy artykuł dotyczy obszaru badań nad zastosowaniem SSN w rolnictwie, ze szczególnym uwzględnieniem monitorowania jakości upraw i zagrożeń czynnikami biotycznymi (chorobami roślin uprawnych na przykładzie pszenicy i pszenżyta). W poprzednim artykule pt. „System oceny zdrowotności zbóż dla gospodarstw rolnych” (Golka i in., 2024), przedstawiliśmy strukturę, przeznaczenie i sposób działania systemu Teledis, pozwalającego na wykonanie diagnoz chorób pszenicy i pszenżyta z wykorzystaniem do tego celu modelu SSN.

System i aplikacja Teledis opracowane zostały przez projekt Grupy Operacyjnej TeleDis realizowany w latach 2021-2022, przez konsorcjum w składzie:

- a) Centrum Doradztwa Rolniczego w Brwinowie;
- b) Instytut Hodowli i Aklimatyzacji Roślin PIB;
- c) Relayonit Sp. z o.o. w Warszawie;
- d) Łódzki Ośrodek Doradztwa Rolniczego;
- e) Świętokrzyski Ośrodek Doradztwa Rolniczego;
- f) Marian Hadrian, prowadzący gospodarstwo rolne w Kobierzycu;
- g) Roman Życiński prowadzący gospodarstwo rolne w Mirogonowicach.

Projekt Grupy Operacyjnej Teledis był finansowany w ramach działania M16 „Współpraca”, Programu Rozwoju Obszarów Wiejskich. Wyżej wymieniony skład konsorcjum projektowego umożliwił skuteczną realizację interdyscyplinarnego projektu uwzględniając wszystkie etapy badań prac rozwojowych, przedwdrożeniowych, wdrożeniowych, upowszechniających i szkoleniowych. W tym artykule przedstawiono wyniki badań przeprowadzonych z zastosowaniem systemu Teledis dla analizy chorób roślin, oceny poprawności diagnoz SSN oraz przedyskutowano podstawowe ograniczenia wpływające na poprawność funkcjonowania aplikacji. Dodatkowe podstawowe informacje o systemie Teledis można znaleźć na stronie <https://teledis.pl>.

3. Struktura systemu Teledis

Poniżej przedstawiono prosty schemat funkcjonowania i wzajemnych zależności poszczególnych składowych systemu Teledis, w tym fazy pozyskania, przepływu i raportowania danych oraz działania aplikacji (rysunek 1).

Zdjęcia z plantacji (detekcja fotograficzna) wprowadzane są bezpośrednio do aplikacji i poddawane analizie w modelu SSN (konwolucyjne sieci neuronowe, CNN). Wyniki obliczane są metodą wyliczenia średniej dla sum odległości każdego kolejnego punktu zbioru badanego względem najbliższego punktu zbioru wzorcowego (z bazy wzorców), gdzie jako odległość rozumiemy odległość sferyczną w trójwymiarowej przestrzeni liczb rzeczywistych. W tym celu niezbędna jest odpowiednia (jakościowo i ilościowo przygotowana) baza wzorców różnych odmian zbóż z objawami chorobowymi oraz bez uszkodzeń. Odpowiednie funkcjonowanie systemu pozwala na stawianie odpowiedniej diagnozy (z wysoką poprawnością i w czasie zbliżonym do rzeczywistego) oraz przesyłanie raportu zwrotnego w odpowiedzi na przesłane zdjęcie porażonej uprawy.

Zastosowanie sztucznych sieci neuronowych (SSN) do diagnozowania chorób roślin od momentu wykonania zdjęć terenowych po wygenerowanie kompleksowego raportu (jak wskazano na rysunku 1), wymagało opracowania systemu Teledis w kilku etapach. Ogólny schemat działania obejmował:

Rysunek 1

Schemat idei funkcjonowania systemu Teledis



Zródło: Zdjęcia wygenerowano z zastosowaniem AI Image Generator.

- 1. Gromadzenie danych** – pozyskiwanie zdjęć roboczych przez pracowników terenowych i rolników za pomocą smartfonów i z zastosowaniem bezzałogowych statków powietrznych; zdjęcia obejmowały różne części rośliny, w tym liście, łodygi, kłosa, w różnych warunkach pogodowych i różnych ujęciach, aby zapewnić kompleksowy obraz na potrzeby opisu wzorców i ostatecznie generowania poprawnej diagnozy.
- 2. Wstępne przetwarzanie danych** tj. ewentualne czyszczenie obrazu, dla usunięcia artefaktów lub nieistotnych danych z obrazów; standaryzowanie rozmiaru, koloru i rozdzielczości obrazu, dla zapewnienia spójności zbioru danych; etykietowanie za pomocą komputerowych narzędzi wizyjnych każdego obrazu dla przypisania odpowiedniej choroby rośliny lub stanu rośliny do określonego wzorca. Efektem było utworzenie oznaczonego zestawu danych do szkolenia SSN.
- 3. Rozwój modelu:**
 - 3.1** Zaprojektowanie architektury konwolucyjnej sieci neuronowej (CNN) odpowiedniej do klasyfikacji obrazów i ekstrakcji funkcji z zastosowaniem wstępnie wyszkolonych modeli. Sieć konwolucyjna jest to rodzaj sieci neuronowej, która analizuje dane przestrzenne, takie jak obrazy. Działa poprzez przekształcanie wejściowego obrazu za pomocą serii warstw konwolucyjnych, związanych z określonymi funkcjami aktywacji. Zasada działania opiera się na operacji konwolucji, która polega na

nałożeniu filtru - niewielkiego macierzy obliczeń - na obraz. Proces ten identyfikuje istotne cechy na obrazie, takie jak krawędzie czy kolory, które są później wykorzystywane do klasyfikacji obrazów.

3.2 Podział danych na zestawy szkoleniowe, walidacyjne i testowe, dla szkolenia i oceny wydajności modelu.

3.3 Trenowanie sieci neuronowej, korzystając z oznaczonego zbioru danych, dostosowując wagi, minimalizując błędy klasyfikacji; dostosowując hiperparametry takie jak szybkość uczenia się, rozmiar partii i liczba epok.

4. Ocena modelu:

4.1 Walidacja - ocena modelu w zestawie walidacyjnym, dla sprawdzenia, że model dobrze generalizuje nowe dane; dostosowanie modelu, jeśli to konieczne, dla poprawy wydajności.

4.2 Testowanie - ocena dokładności, precyzji modelu na zestawie testowym, dla potwierdzenia jego przydatności w rzeczywistej diagnostyce.

5. **Wdrożenie** modelu na serwerze lokalnym (IHAR-PIB) i jako część aplikacji mobilnej dedykowanej docelowym użytkownikom (rolnikom, doradcom, naukowcom).

6. **Generowanie raportów** – interpretacja przesłanego obrazu ze wskazaniem prawdopodobieństwa i nasilenia chorób za pośrednictwem przyjaznego interfejsu (aplikacja internetowa, aplikacja mobilna).

7. **Ciągłe doskonalenie** – mechanizm informacji zwrotnej dla użytkowników, będzie dostarczał informacji na temat dokładności przewidywań modelu. Okresowo model będzie uczony przy użyciu nowych danych, aby z czasem poprawić jego wydajność.

4. Wyniki analiz SSN i potencjalne ograniczenia systemu Teledis

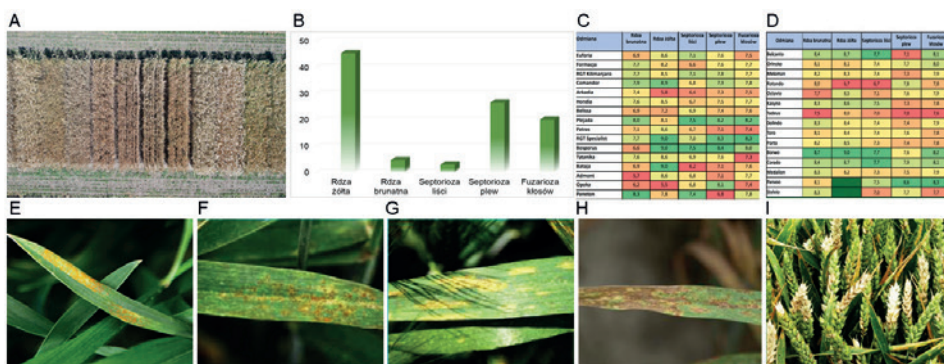
Aktualnie w bazie znajduje się 422 wzorce pszenicy i 177 wzorców pszenżyta opracowanych dla kolekcji pozyskanych zdjęć przekraczającej liczbę 3000. Rozkład wzorców chorób dla poszczególnych odmian jest stosunkowo nierównomierny. Spośród 46 odmian pszenicy, dla pięciu możliwe było opisanie wzorców porażenia więcej niż 2 chorobami. W projekcie opracowano wzorce głównie dla pięciu chorób najpowszechniej występujących tj.: rdzy żółtej (*Puccinia striiformis*), rdzy brunatnej (*Puccinia triticina*), septoriozy plew (*Parastagonospora nodorum*), septoriozy paskowanej liści (*Zymoseptoria tritici*) i fuzariozy kłosów (*Fusarium* spp.).

W wielu przypadkach, pomimo sztucznych inokulacji patogenami, porażenia chorobami nie występowały; np. w 2022 i 2023 roku z poletek IHAR-PIB w Radzikowie (rysunek 2A) uzyskano zdjęcia pszenicy głównie dla trzech rodzajów chorób: rdzy żółtej dla 15 odmian zbóż (ok. 50% wszystkich zobrazowań cho-

rób roślin), septoriozy plew dla 10 odmian (27% zobrazowań) oraz fuzariozy dla 8 odmian (ok. 20% zobrazowań) (rysunek 2B). W tym zakresie, ograniczenia w możliwości budowy odpowiedniej bazy wzorców (pozyskania i przygotowania dużej ilości opisanych wzorców) dla wszystkich odmian wynikają z zróżnicowanej odporności poszczególnych odmian zbóż (pszenicy i pszenżyta) na określone choroby (rysunek 2C i 2D). Z jednej strony brak występowania chorób uniemożliwia pozyskanie wzorców dla odmian odpornych. Z drugiej jednak strony, objawy jednoznaczne i występujące w stosunkowo dużym nasileniu dla roślin wrażliwych na choroby pomimo, że stanowią znakomite wzorce, nie odzwierciedlają rzeczywistych warunków i nasilenia występowania choroby w polu (rysunek 2E-2I). Baza wzorców nie może zatem być budowana jedynie w ramach jednoznacznych objawów chorobowych dla wszystkich odmian. Uczenie SNN wymaga większego zróżnicowania nasilenia choroby dla różnych odmian, ponieważ raporty zwrotne nie będą generowane poprawnie w przypadku tendencyjnego uczenia SSN.

Rysunek 2

Występowanie chorób na poletkach doświadczalnych IHAR-PIB w Radzikowie



A – poletka doświadczalne z sztuczną inokulacją patogenów roślinnych (fot. M. Wiaderny);

B – procentowy udział zdjęć pozyskanych z widocznymi objawami poszczególnych chorób na różnych odmianach pszenicy i pszenżyta w latach 2021-2022;

C, D – stopień odporności (w skali wg Coboru 1 – podatna; 9 – odporna) odmian pszenicy ozimej (C) i pszenżyta ozimego (D), stosowanych w doświadczeniach polowych;

E-I – objawy chorobowe w kolejności dla rdzy żółtej (*Puccinia striiformis*), rdzy brunatnej (*Puccinia triticina*), septoriozy plew (*Parastagonospora nodorum*), septoriozy paskowanej liści (*Zymoseptoria tritici*), i fuzariozy kłosów (*Fusarium* spp.) (fot. T. Góral);

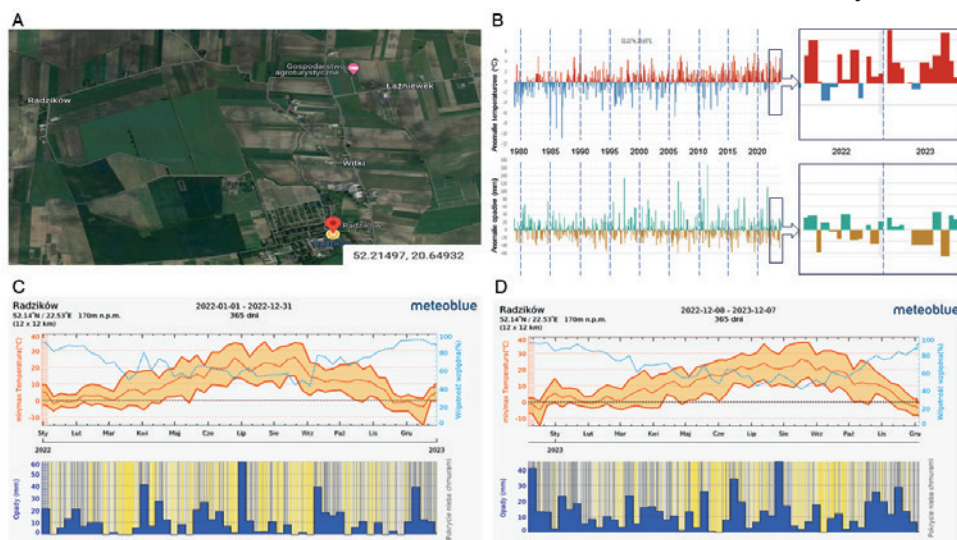
Źródło: Opracowanie własne.

Innym czynnikiem, wpływającym na pozyskanie właściwych wzorców lub ograniczenia w ich pozyskaniu, są warunki pogodowe w poszczególnych latach, w tym szczególnie rozkład temperatur i opadów. Należy mieć na względzie, że:

1. Rozwojowi grzyba powodującego rdzę żółtą sprzyja duża wilgotność powietrza i intensywne nasłonecznienie. W temperaturze 10-15°C, urediniospory patogena mogą przemieszczać się na duże odległości i skutecznie penetrować liście. Grzyb przestaje się rozwijać w temperaturze powyżej 21°C oraz poniżej 0°C.
2. Optymalnymi warunkami do rozwoju grzyba powodującego rdzę brunatną jest temperatura 12-24°C w dzień i 0-12°C nocą. Rdza do rozwoju nie potrzebuje opadów deszczu, ale wilgotność powietrza musi być bliska 100%.
3. Septorioza paskowana liści to choroba atakująca przede wszystkim pszenicę, choć objawy obserwowane są też na pszenzycie w warunkach wysokiej wilgotności powietrza oraz przy temperaturze powietrza na poziomie 10-15°C. W temperaturze poniżej 7°C nie dochodzi do infekcji roślin. Zarodniki są przenoszone z kroplami deszczu.
4. Grzyby wywołujące septoriozę plew infekują, gdy temperatura wynosi 14-24°C w dzień i 0-14°C w nocy. Patogen ten rozprzestrzenia się w dużym stopniu przez konidia z kroplami deszczu. Choroba występuje w większym nasileniu po łagodnej zimie.
5. Fuzariozę kłosów powodują różne gatunki grzybów z rodzaju *Fusarium* (*F. graminearum*, *F. culmorum*, *F. avenaceum*, *F. poae*, *Microdochium nivale*). W łanie zboża grzyby rozprzestrzeniają się głównie za pomocą zarodników konidialnych przenoszonych z resztek poźniwnych lub z wiatrem, osiadających na wykłoszonych zbożach. Rozwojowi choroby sprzyja wysoka wilgotność powietrza, częste opady deszczu i temperatura 12-24°C w dzień oraz 5-12°C w nocy. Porażenie jest tym większe, im w sezonie obserwujemy łagodniejszą jesień i zimę oraz chłodniejszą i bardziej mokłą wiosnę.

W sezonach 2022 i 2023 charakterystyczne były dość ciepłe zimy i stosunkowo mokry luty, a następnie stosunkowo chłodny i suchy kwiecień-maj oraz ciepła i bardzo sucha druga połowa wiosny i początek lata (rysunek 3). Szczególnie 2022 rok uznany został jako bardzo ciepły i suchy. Był to szósty najcieplejszy rok w XXI wieku (podsumowanie IMGW-PIB), natomiast obszarowo uśredniona suma opadów atmosferycznych wyniosła 87,4% normy określonej na podstawie pomiarów w latach 1991-2020. Warunki pogodowe (rysunek 3) w miejscowości Radzików były zatem sprzyjające rozwojowi rdzy żółtej, ale nie brunatnej. Rdzę brunatną obserwowano w mniejszym nasileniu i w znacznie późniejszych fazach rozwoju roślin, gdy czasami było już trudno rozróżnić jej występowanie względem uszkodzeń liści powodowanych przez inne czynniki. Podobna zależność dotyczyła preferencyjnych warunków dla septoriozy plew szczególnie w sezonie 2022 oraz fuzariozy w obu sezonach, ale nie dla septariozy paskowanej liści.

Rysunek 3



- A – Mapa satelitarna miejscowości Radzików (<https://www.google.pl/maps/>);
- B – anomalie klimatyczne za lata 1980-2023 (temperatura i opady; powiększono dane dla 2022 oraz 2023);
- C, D – dane meteorologiczne w ujęciu rocznym (temperatura i opady; odpowiednio dla roku 2022 i 2023). Anomalie wskazują różnicę względem 30-letniej średniej klimatycznej 1980-2010; kolor czerwony – miesiące, w których temperatura (oC) i opady (mm) przewyższają wartości średnie, kolor niebieski – wartości niższe niż średnia.

Źródło: Dane klimatyczne i meteorologiczne wygenerowano w serwisie Meteoblue (<https://www.meteoblue.com/pl>).

Innym typem ograniczeń funkcjonowania sieci SSN, w tym również aplikacji Teledis mogą być warunki techniczne i jakość zdjęć pozyskanych jako wzorce. Poniżej opisane zostały powszechne problemy wynikające z artefaktów występujących na zdjęciach klasyfikowanych jako wzorce i metod diagnozowania zdjęć testowych, jak również sposoby zapobiegania nieprawidłowym diagnozom.

Przyjmując za podstawę bazę wzorców zbóż opracowaną w latach 2021-2022 w ramach projektu Teledis, przeprowadzono uproszczoną analizę poprawności diagnozowania zdjęć roślin pszenicy uzyskanych na poletkach doświadczalnych IHAR-PIB w Radzikowie wiosną i latem 2023 roku. Zakres i dobór przyjętych do analizy chorób i odmian pszenicy, był wybrany mając na względzie poprawną strukturę i liczbę wzorców w bazie Teledis oraz jakość zdjęć testowych. Do analiz wybrano losowo po 10 zdjęć odmian Parada i Opoka z objawami rdzy żółtej oraz po 10 zdjęć odmian Tytanika i Hondia z objawami fuzariozy kłosów spośród sumarycznej puli 424 zdjęć z poletek doświadczalnych (w tym 240 zdjęć z objawami rdzy żółtej oraz 184 zdjęcia z objawami fuzariozy kłosów). Rysunek 4 przedstawia

przykładowe ekrany zgłoszenia zdjęcia do ekspertyzy (rysunek 4A), kartę diagnozy (rysunek 4B), ekran ekspertyzy dostępny dla eksperta (rysunek 4C), wynik analizy dostępny dla eksperta (rysunek 4D).

Rysunek 4

Przykładowe etapy analizy zgłoszonych do diagnozy zdjęć w panelu eksperckim



- A – ekran zgłoszenia zdjęcia do ekspertyzy;
- B – karta diagnozy;
- C – ekran ekspertyzy dostępny dla eksperta;
- D – wynik analizy dostępny dla eksperta.

Źródło: Opracowanie własne.

Przedmiotem badań była poprawność diagnoz porażenia określonym patogenem raportowana na karcie diagnozy aplikacji. Ocena była przeprowadzona metodą zero-jedynkową (0 – diagnoza niepoprawna; 1 – diagnoza poprawna). Jednocześnie sprawdzany był czas stawiania diagnozy oraz wartość średniej najlepszego dopasowania diagnozy, będąca wartością średnią dla sum odległości każdego kolejnego punktu zbioru badanego względem najbliższego punktu zbioru wzorcowego, gdzie jako odległość przyjęto odległość sferyczną w trójwymiarowej przestrzeni liczb rzeczywistych. Wyniki testów przedstawiono w tabelach 1-4. Bezbledne wyniki (100% poprawnych diagnoz) otrzymano dla odmiany pszenicy Parada porażonej rdzą żółtą oraz dla pszenicy odmiany Honda z objawami fuzariozy kłosów. Mniejszą precyzję diagnozy otrzymano analizując objawy rdzy żółtej dla pszenicy odmiany Opoka (90%) oraz fuzariozy kłosów dla pszenicy Tytanika (80%). Na podstawie analizy można założyć, że diagnoza jest wiarygodna, jeżeli wartości

średniej odległości mieszczą się w granicach wartości do 4500. Najniższe wartości średnie i odchylenie standardowe uzyskano w grupie testów odmiany Hondia. Można przyjąć, że dla tej odmiany przygotowano i opisano najbardziej precyzyjnie wzorce, w tym wzorce bezpośrednio służące do weryfikowania fuzariozy kłosów.

Tabela 1

Diagnozy objawów rdzy żółtej dla pszenicy odmiany Parada

Lp.	Symbol Testu	Czas diagnozy (Minuty)	Ocena (0/1)	Średnia odległość
1.	Test x	30	1	2808
2.	Test x2	29	1	2503
3.	Tdsc184	29	1	2878
4.	Tdsc249	30	1	2402
5.	Tdsc183	31	1	2887
6.	Tdsc173	29	1	2570
7.	Tdsc175	28	1	2983
8.	Tdsc187.1	29	1	2282
9.	Tdsc176	27	1	2597
10.	Tdsc209	27	1	2846
Odchylenie standardowe próbki				236,55

Źródło: Opracowanie własne.

Tabela 2

Diagnozy objawów rdzy żółtej dla pszenicy odmiany Opoka

Lp.	Symbol Testu	Czas diagnozy (Minuty)	Ocena (0/1)	Średnia odległość
1.	Tdsc359	26	1	4234
2.	Tdsc361	32	1	3601
3.	Tdsc362	33	0	3868
4.	Tdsc364	28	1	3727
5.	Tdsc365	45	1	3603
6.	Tdsc366	31	1	2170
7.	Tdsc367	42	1	3352
8.	Tdsc368	32	1	3206
9.	Tdsc369	31	1	2684
10.	Tdsc370	32	1	3558
Odchylenie standardowe próbki				595,61

Źródło: Opracowanie własne.

Tabela 3

Diagnozy objawów fuzariozy kłosów dla pszenicy odmiany Hondia

Lp.	Symbol Testu	Czas diagnozy (Minuty)	Ocena (0/1)	Średnia odległość
1.	Tdsc620	28	1	1320
2.	Tdsc614	30	1	1490
3.	Tdsc615	28	1	1352
4.	Tdsc616	29	1	1654
5.	Tdsc617	30	1	1643
6.	Tdsc618	30	1	1587
7.	Tdsc619	28	1	1571
8.	Tdsc620	30	1	1302
9.	Tdsc621	28	1	1604
10.	Tdsc622	29	1	1223
Odchylenie standardowe próbki				160,37

Źródło: Opracowanie własne.

Tabela 4

Diagnozy objawów fuzariozy kłosów dla pszenicy odmiany Tytanika

Lp.	Symbol Testu	Czas diagnozy (Minuty)	Ocena (0/1)	Średnia odległość
1.	Tdsc589	31	1	2911
2.	Tdsc586	32	1	2536
3.	Tdsc573	29	1	2015
4.	Tdsc341	30	1	1971
5.	Tdsc575	29	1	2509
6.	Tdsc576	28	1	2399
7.	Tdsc598	30	1	2124
8.	Tdsc582	27	0	2293
9.	Tdsc572	29	0	2274
10.	Tdsc60631	28	1	2439
Odchylenie standardowe próbki				279,04

Źródło: Opracowanie własne.


Poniżej przedstawiono typowe przykłady błędnie postawionych diagnoz wraz z przyczyną ich powstania. System wraz z bazą wzorców został przygotowany w sposób umożliwiający rozpoznawanie barw (RGB) oraz kształtów (np. kłos,

liść, łodyga, gleba). W jednym i drugim przypadku diagnoza może być postawiona nieprawidłowo, mając na względzie, że sieci SSN przetwarzają informacje o kolorach, traktując wartości RGB jako cechy liczbowe w warstwie wejściowej. Trójwymiarowa przestrzeń liczb rzeczywistych jest wykorzystywana do reprezentowania i przetwarzania informacji o kolorach w sposób ilościowy i systematyczny.

Zdjęcie testowe Tdsc362 reprezentuje objawy rdzy żółtej dla pszenicy odmiany Opoka. Objawy na zdjęciu zdiagnozowane zostały jednak jako liście porażone septoriozą plew (rysunek 5). Zbyt duża wielobarwność zdjęcia uniemożliwia jednoznaczne zdefiniowanie liczbowej reprezentacji RGB pikseli i prawidłową diagnozę zgodnie wyuczonym modelem dla różnych chorób: rdzy żółtej i septoriozy plew. Zdjęcie zmodyfikowano, zmniejszając i uwypuklając miejsca z liśćmi porażonymi rdzą żółtą. Ponowno próbę (test Tdsc362.1) uzyskując poprawną diagnozę porażenia.

Rysunek 5

Diagnoza Tdsc.362 (lewy panel) oraz diagnoza Tdsc362.1 (prawy panel) dla zmodyfikowanego zdjęcia




Zródło: Opracowanie własne.

Podobnie, pomimo wyraźnych objawów rdzy żółtej na liściach odmiany Opoka, zdjęcie Tdsc359 zdiagnozowane zostało zgodnie z wzorcem septoriozy plew, ze względu na podobieństwo kolorystyczne wzorca do gleby widocznej na analizowanym zdjęciu testowym (rysunek 6). Usunięcie fragmentu z glebą z zdjęcia poprawiło postawioną diagnozę. Alternatywnym rozwiązaniem jest również modyfikacja jakościowa i ilościowa biblioteki wzorców dla poprawienia możliwości rozróżnienia choroby.

Diagnoza fuzariozy kłosa dla pszenicy odmiany Tytanika była problematyczna ze względu na dużą liczbę miejsc z przebarwieniami zdjęcia testowego. Początkowo uzyskano diagnozę „rdza brunatna” (rysunek 7). Modyfikacje wzorców nie przyniosły oczekiwanej zmiany diagnozy. Zdjęcie testowe T582 poddano modyfikacji polegającej na zmniejszeniu powierzchni dla określenia fragmentu kłosa porażonych przez grzyby powodujące fuzariozę (test Tdsc582.1) i otrzymano prawidłową diagnozę.

Rysunek 6


Wzorec septoriozy plew i diagnoza Tdsc 359 (lewy panel) oraz modyfikacja zdjęcia testowego wraz z poprawną diagnozą (prawy panel)



Źródło: Opracowanie własne.

Rysunek 7

Diagnoza T582 (lewy panel) oraz diagnoza Tdsc582.1 (prawy panel) dla zmodyfikowanego zdjęcia




Źródło: Opracowanie własne.

Inną strategię należało zastosować względem zdjęcia testowego Tdsc572, przedstawiającego odmianę Tytanika z fuzariozą kłosów, a zdiagnozowanego jako objawy rdzy brunatnej (rysunek 8). Korekty zdjęcia testowego nie przyniosły skutku, przeciwnie do poprawnej diagnozy po wprowadzeniu dodatkowego wzorca.

Rysunek 8

Diagnoza Tdsc572 (lewy panel) oraz diagnoza Tdsc572.1 (prawy panel) dla zmodyfikowanego zdjęcia




Źródło: Opracowanie własne.

Poniżej przedstawiono jeszcze dwa dodatkowe przykłady niepoprawnie zdiagnozowanych zdjęć testowych, w których błędne dopasowanie było wynikiem artefaktu prześwietlenia zdjęcia (silnego nasłonecznienia żółkniętego liścia) oraz braku jednoznacznych objawów chorobowych (rysunek 9).

Rysunek 9

Niepoprawne dopasowanie diagnozy „rdza żółta” jako wynik artefaktu prześwietlenia zdjęcia (panel lewy) oraz brak dopasowania dla słabo porażonej próbki (panel prawy)



Źródło: Opracowanie własne.

5. Podsumowanie i wnioski

Szybkość rozwoju aplikacji diagnozującej choroby roślin jest w dużym stopniu zależna od możliwości pozyskania prawidłowych zdjęć wzorców (warunki pogodowe dla występowania chorób), zróżnicowania testowanych odmian i nasilenia choroby, jak również eksperckiego opracowania wzorców. Analizując diagnostykę aplikacji Teledis, stwierdzono, że na 40 przeprowadzonych testów, w 3 przypadkach prognozy były błędne. Poprawność diagnozowania osiągnięto w 93% przypadków. Jak wynika z przeprowadzonej analizy, błędy wynikały z braku odpowiednich wzorców w bazie lub złej jakości zdjęcia testowego poddanego analizie SSN. Lu i in. (2017) wskazują na podobne zależności w diagnostyce porażen pszenicy. Problemy z przygotowaniem odpowiednich wzorców, a następnie testowaniem zdjęć z warunków polowych, wynikały głównie z: złożonego kolorystycznie tła zdjęć; różnych warunków pogodowych wykonania zdjęć, skutkującego zmiennym oświetleniem, rozmyciem; współwystępowania wielu liści lub wielu obszarów chorobowych na jednym obrazie; różnych etapów rozwoju choroby; podobnego wyglądu różnych chorób pszenicy (Lu i in., 2017). O ile uzyskany wynik poprawności diagnozowania pszenicy w aplikacji Teledis na poziomie 93% można przyjąć jako satysfakcjonujący, należy mieć na uwadze potrzebę ciągłego uzupełniania bazy wzorców, ze szczególnym uwzględnieniem takich porażen jak septorioza paskowana liści czy rdza brunatna. Ograniczeniem aplikacji Teledis

jest również wykonywanie analizy w czasie 27-33 minut. W miarę rozwoju bazy wzorców i aplikacji czas ten będzie zbliżony do czasu rzeczywistego analiz.

Przeprowadzona analiza pozwoliła również na określenie ogólnych założeń niezbędnych dla poprawnej diagnozy. Szczególnie ważnym wydaje się być odpowiednie przygotowanie wzorców dla procesu uczenia SSN z kilku powodów:

1. SSN uczą się na przykładach. Zapewniając zróżnicowany i reprezentatywny zestaw wzorców w bazie danych szkoleniowych, sieć ma możliwość poznania podstawowych wzorców i relacji obecnych w danych.
2. Celem uczenia SSN jest umożliwienie dobrego uogólniania nowych, niewidocznych danych. Obszerna baza danych pomaga sieci nauczyć się rozpoznawać i uogólniać wzorce, zamiast zapamiętywać konkretne przypadki.
3. Zróżnicowana baza danych pomaga sieci uodpornić się na zmiany i szумы w danych. Uwzględnienie szerokiej gamy zróżnicowanych wzorców gwarantuje, że sieć poradzi sobie z różnymi scenariuszami i warunkami, dzięki czemu będzie bardziej niezawodna w rzeczywistych zastosowaniach.
4. SSN, zwłaszcza głębokie sieci neuronowe, uczą się złożonych reprezentacji hierarchicznych. Dobrze przygotowana baza danych umożliwi sieci wychwytywanie skomplikowanych wzorców i relacji zachodzących w danych, co pozwala na dokonywanie wyrafinowanych przewidywań.
5. Zróżnicowana baza danych pomaga zapobiegać nadmiernemu dopasowaniu SSN, tj. sytuacji, gdy model zbyt dobrze uczy się danych, w tym szumów i wartości odstających, ale nie udaje mu się uogólnić tych informacji na nowe dane. Udostępniając szeroki zakres przykładów problem może zostać częściowo ograniczony.
6. Proces uczenia obejmuje dostosowywanie parametrów (wag i odchyień) sieci w celu zminimalizowania różnicy między przewidywanymi i rzeczywistymi wynikami. Dobrze przygotowana baza danych przyczynia się do efektywniejszego procesu optymalizacji, umożliwiając zbieżność sieci w kierunku rozwiązania dobrze generalizującego.

W celu identyfikacji porażen roślin stosuje się dziś czujniki systemu obrazowania RGB, które gromadzą dane pod różnymi kątami i w obrazowaniu 3D (Singh i in., 2020). Wykorzystywane są również inne techniki obrazowania np.: obrazowanie termiczne, obrazowanie multispektralne i hiperspektralne, obrazowanie fluorescencyjne, stosowane indywidualnie lub w połączeniu z obrazowaniem widzialnym (RGB). Wszystkie te technologie mają na celu wykrywanie porażen roślin z większą precyzją i na znacznie wcześniejszych etapach porażenia (Bauriegel, 2011; Alisaac i Mahlein, 2023). Metody te coraz częściej integrowane są z SSN i modelami uczenia maszynowego dla poprawienia i automatyzacji diagnostyki, szybkiej interwencji i zarządzania uprawami. Dane i technologie mogą być również wykorzystane do wprowadzenia ukierunkowanych zabiegów zautomaty-

zowanymi maszynami rolniczymi (opryskiwaczami). Instalowanie kamer zbierających obrazy na opryskiwaczach i wykorzystanie SSN umożliwia automatyczną i szybką analizę dużych zbiorów danych obrazowych, dzięki czemu można je skalować w czasie rzeczywistym podczas przejazdu rozległymi polami uprawnymi i sterować opryskiem (regulowaną dawką cieczy). Ta integracja technologii obrazowania i sztucznej inteligencji jest niezwykle obiecująca również dla mapowania upraw (np. z zastosowaniem bezzałogowych statków powietrznych) i rejestracji ognisk porażenia roślin. Pozwoli to na wdrażanie do praktyki rolniczej oprysków punktowych, co z kolei umożliwi duże ograniczenie zużycia pestycydów i herbicydów. Integrowanie tych trzech kierunków rozwoju technologii diagnostyki chorób roślin daje szansę wprowadzenia do praktyki wielowariantowej technologii ochrony na miarę potrzeb gospodarstw rolnych. Dalsze prace w tym zakresie, stanowią podstawę dla rozwoju i upowszechniania również systemu Teledis. Planuje się w tym zakresie współpracę z państwowym i prywatnym doradztwem rolniczym oraz z IOR PIB i COBORU. Należy nadmienić, że oprócz aplikacji diagnozującej, system Teledis może dostarczyć rolnikom możliwość korzystania z porad doradców rolniczych oraz ekspertów z jednostek naukowo-badawczych oraz Centrum informacyjnego dla rolników i doradców rolniczych (opisanego w artykule Golka i in., 2024).

LITERATURA

1. Ackerman, A.J., Holmes, R., Gaskins, E., Jordan, K.E., Hicks, D.S., Fitzgerald, J., Griffey, C.A., Mason, R.E., Harrison, S.A., Murphy, J.P., Cowger, C., Boyles, R.E. (2022). Evaluation of methods for measuring Fusarium-damaged kernels of wheat. *Agronomy*, 12, 532. <https://doi.org/10.3390/agronomy12020532>
2. Aguilar-Lazcano, C.A., Espinosa-Curiel, I.E., Ríos-Martínez, J.A., Madera-Ramírez, F.A., Pérez-Espinosa, H. (2023). Machine learning-based sensor data fusion for animal monitoring: scoping review. *Sensors*, 23, 5732. <https://doi.org/10.3390/s23125732>
3. Alisaac, E., Mahlein, A.K. (2023). Fusarium head blight on wheat: biology, modern detection and diagnosis and integrated disease management. *Toxins (Basel)*, 15(3), 192. doi: 10.3390/toxins15030192
4. Ayoubi, S., Pilehvar, A., Mokhtari, P., Sahrawat K.L. (2011). *Application of artificial neural network (ANN) to predict soil organic matter using remote sensing data in two ecosystems*. Ed: Islam Atazadeh: Biomass and Remote Sensing of Biomass. InTech. doi: 10.5772/18956
5. Bartlett, J. (2019). The People vs Tech: How the Internet is Killing Democracy (and How We Save It). Ludzie przeciw technologii. Jak Internet zabija demokrację (i jak ją możemy ocalić). *Post Factum*. ISBN: 978-83-811-0724-2
6. Barwicki, J., Hryniewicz, M., Grzybek, A. (2020). Yield forecasting using artificial intelligence. *Polish Technical Review*, 1, 19-22. DOI 10.15199/180.2020.1.3

7. Bauriegel, E., Giebel, A., Geyer, M., Schmidt, U., Herppich, W.B. (2011). Early detection of fusarium infection in wheat using hyper-spectral imaging. *Computers and Electronics in Agriculture*, 75, 304-312. doi:10.1016/j.compag.2010.12.006
8. Bi, K., Xie, L., Zhang, H., Chen, X., Gu, X., Tian Q. (2023). Accurate medium-range global weather forecasting with 3D neural networks. *Nature*, 619, 533-538. <https://doi.org/10.1038/s41586-023-06185-3>
9. Chaaro, L., Martínez, A.L. (2020). Crop and weed detection using image processing and deep learning techniques. Bachelor degree project in production engineering. University of Skövde. <https://www.diva-portal.org/smash/get/diva2:1447357/FULL-TEXT01.pdf>
10. Chen, L., Chen, Z., Zhang, Y. Zhang, Y., Liu, Y., Osman, A.I., Farghali, M., Hua, J., Al-Fatesh, A., Ihara, I., Rooney D.W., Yap P.S. (2023). Artificial intelligence-based solutions for climate change: a review. *Environ Chem Lett.*, 21, 2525-2557. <https://doi.org/10.1007/s10311-023-01617-y>
11. Delwiche, S.R., Rodriguez, I.T., Rausch, S.R., Graybosch, R.A. (2019). Estimating percentages of Fusarium-damaged kernels in hard wheat by near-infrared hyperspectral imaging. *Journal of Cereal Science*, 87, 18-24. <https://doi.org/10.1016/j.jcs.2019.02.008>
12. Fente, D.N., Kumar Singh, D. (2018). Weather forecasting using artificial neural network, Second International Conference on Inventive Communication and Computational Technologies (ICICCT), Coimbatore, India, 2018, pp. 1757-1761, doi: 10.1109/ICICCT.2018.8473167
13. Golka, W., Szechyńska-Hebda M., Golka, A., Góral, T., Bomberski, A., Kowalska, J. (2024). System oceny zdrowotności zbóż dla gospodarstw rolnych. *Zagadnienia Doradztwa Rolniczego. Nr. 1/24(115)*, ss.98-118.
14. Kadir, M., Hines, E., Qaddoum, K., Collier, R., Dowler, E., Grant, W., Leeson, M., Iliescu, D., Subramanian, A., Richards, K., Merali, Y., Napier, R. (2013). Food security risk level assessment: a fuzzy logic-based approach. *Applied Artificial Intelligence*, 27, 50-61. <https://doi.org/10.1080/08839514.2013.747372>
15. Kamyab, H., Khademi, T., Chelliapan, S., Kamarposhti, M.S., Rezania, S., Yusuf, M., Farajnezhad, M., Abbas, M., Jeon, B.H., Ahn, Y. (2023). The latest innovative avenues for the utilization of artificial Intelligence and big data analytics in water resource management. *Results in Engineering*, 20, 101566. <https://doi.org/10.1016/j.rinen.2023.101566>
16. Lu, J., Hu, J., Zhao, G., Mei, F., Zhang C. (2017). An in-field automatic wheat disease diagnosis system. *Computers and Electronics in Agriculture*, 142A, 369-379. <https://doi.org/10.1016/j.compag.2017.09.012>
17. Łabańska, M. (2021). Wykorzystanie elektronicznego języka do badania żywności. *Ziemiański Polski*, 3, 33-39, ISSN 1425-4263.
18. Monteiro, A.L., Souza, M.F., Lins, H.A., Teófilo T.M.S., Júnior, A.P.B., Silva, D.V., Mendonça, V. (2021). A new alternative to determine weed control in agricultural systems based on artificial neural networks (ANNs). *Field Crops Research*, 263, 108075. <https://doi.org/10.1016/j.fcr.2021.108075>
19. Niedbała, G., Przybył, J., Boniecki, P., Sęk, T. (2005). Analiza założeń dla modelowania plonu buraka cukrowego z wykorzystaniem sztucznych sieci neuronowych. *Inżynieria Rolnicza*, 2, 123-130. ISSN 2083-1587.