



SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO



ScanSpectrum
qed.ai

Raport końcowy

Tytuł operacji: ScanSpectrum - innowacja w polskim rolnictwie

Projekt współfinansowany jest ze środków Unii Europejskiej w ramach działania „Współpraca”
Programu Rozwoju Obszarów Wiejskich na lata 2014-2020

Numer umowy: 00080.DDD.6509.00282.2022.03

Budżet operacji: 6 642 692,78 zł

Kwota dofinansowania: 5 080 975,00 zł, w tym ze środków EFRROW w wysokości 3 233 024,29
zł, z krajowych środków publicznych w wysokości 1 847 950,61 zł.



SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO

Spis treści

Wprowadzenie.....	4
Zakres wykonanych prac	4
1. Etap 1: Przygotowanie operacyjne i organizacja badań (01.2023–04.2023)	6
1.1. Obudowy do prototypów wykonane metodą wtrysku	6
1.2. Budowa i programowanie prototypów spektrometru	8
1.3. Przygotowanie aplikacji mobilnej do badań	10
1.4. Wykonanie analiz przestrzennych i ustalenie zakresu prac badawczych.....	13
1.5. Przeprowadzenie badań glebowych.....	20
1.6. Ustalenie taktyk analizy i gromadzenia danych.....	23
1.7. Metodologia pobierania prób i pierwsza kampania pomiarowa	28
1.8. Podsumowanie.....	31
2. Etap 2: Rozszerzenie działań badawczych i rozwój modeli analitycznych (05.2023–08.2023)	32
2.1. Prace polowe	32
2.2. Opracowanie danych.....	37
2.3. Wstępne analizy danych spektralnych	40
2.4. Analizy przestrzenne i mapy nawożenia	43
2.5. Analizy mapy plonów.....	46
2.6. Testowe modele suchej masy i mapy wilgotności uprawy	50
2.7. Podsumowanie.....	52
3. Etap 3: Udoskonalenie modeli i analiza plonu (09.2023–11.2023).....	52
3.1. Analiza parametrów plonu z punktów eksperymentalnych.....	52
3.2. Analiza danych z urządzeń referencyjnych.....	62
3.3. Usprawnienia hardware, firmware i aplikacji mobilnej	64
3.4. Zakup części i produkcja serii pilotażowej na drugi sezon pomiarowy	66
3.5. Rozpoczęcie budowy systemu do wytwarzania map nawożenia.....	68
3.6. Podsumowanie.....	72



SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO

4. Etap 4: Zaawansowana analiza i przygotowanie do kolejnego sezonu pomiarowego (12.2023–03.2024)	73
4.1. Zaawansowana analiza danych	73
4.2. Usprawnienie urządzeń pomiarowych.....	84
4.3. Przygotowanie do badań polowych	88
4.4. Środowisko do generowania map nawozowych	91
4.5. Podsumowanie.....	95
5. Etap 5: Kolejny sezon badawczy, przygotowanie finalnych rozwiązań do wdrożenia (04.2024–04.2025)	96
5.1. Pobór i pomiary próbek roślinnych - sezon 2024	96
5.2. Przygotowanie dokumentacji technicznej	102
5.3. Analiza danych z obydwu sezonów pomiarowych	105
5.4. Wdrożenie modeli i systemu map nawożenia.....	114
6. Podsumowanie projektu	120
7. Rekomendacja dalszych działań	124



SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO

Wprowadzenie

Projekt ScanSpectrum – Innowacja w Polskim Rolnictwie został zrealizowany w odpowiedzi na rosnące potrzeby precyzyjnego monitorowania upraw i optymalizacji procesów nawożenia. Jego celem było opracowanie i wdrożenie nowoczesnego systemu pomiarowego umożliwiającego szybkie i precyzyjne analizy parametrów roślin w terenie.

Operacja trwała od 1 stycznia 2023 r. do 30 kwietnia 2025 r. i została zakończona. Projekt realizowało konsorcjum złożone z firmy QED Poland sp. z o. o., Szkoły Głównej Gospodarstwa Wiejskiego, Instytutu Nowoczesnego Rolnictwa oraz rolników. W ramach przedsięwzięcia przeprowadzono pięć etapów badań, obejmujących m.in. kampanie pomiarowe na polach badawczych, analizy roślin oraz danych spektralnych, budowę modeli predykcyjnych i wytwarzanie rozwiązań software.

Kluczowym efektem projektu było stworzenie ulepszonej wersji prototypu urządzenia ScanSpectrum, wykorzystującego technologie optyczne i algorytmy machine learning do analizy kondycji roślin w zakresie widzialnym i bliskiej podczerwieni. Dzięki temu możliwe stało się prowadzenie pomiarów w czasie rzeczywistym, eliminując konieczność transportu próbek do laboratoriów.

Raport końcowy przedstawia szczegółowy opis przeprowadzonych badań, wdrożonych technologii oraz osiągniętych wyników, potwierdzając skuteczność i innowacyjność opracowanego rozwiązania dla rolnictwa precyzyjnego.

Zakres wykonanych prac

Etap 1 (01.2023–04.2023): W pierwszym etapie skupiono się na przygotowaniu operacyjnym, które obejmowało przeprowadzenie badań glebowych i utworzenie siatki badań na podstawie danych satelitarnych. Dodatkowo przygotowano środowisko testowe i biblioteki danych niezbędne do dalszych prac badawczo-rozwojowych, a także rozpoczęto pierwsze działania polowe oraz organizację spotkań i procedur wspierających całość operacji.

Etap 2 (05.2023–08.2023): Drugi etap polegał na rozszerzeniu działań badawczych, co obejmowało intensyfikację pobierania próbek roślin, dzieląc je na części w zależności od fazy rozwojowej oraz szczegółową analizę parametrów łanu. W ramach tego okresu rozwijano modele analizy parametrów roślin, tworzone były prototypowe rozwiązania oprogramowania pomiarowego oraz testowe mapy nawożenia, a także zbierano dane z maszyn rolniczych, co umożliwiło dalszą kalibrację metod badawczych.



SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO

Etap 3 (09.2023–11.2023): W trzecim etapie kontynuowano pomiary próbek i analizę danych, koncentrując się również na danych z plonowania. W tym okresie udoskonalano modele predykcyjne, wdrażano algorytmy analizy przestrzennej parując je z danymi z sensorów, co umożliwiło przeprowadzenie szczegółowej analizy statystycznej i weryfikację jakości zebranych danych, stanowiąc fundament pod przyszłe rekomendacje dotyczące optymalizacji działań agrotechnicznych. Rozpoczęto również proces usprawniania samego urządzenia i produkcji pilotażowej do przeprowadzenia rozszerzonych badań w kolejnym sezonie pomiarowym.


Etap 4 (12.2023–03.2024): Czwarty etap to faza zaawansowanej analizy, podczas której przeprowadzono dogłębną analizę statystyczną i przestrzenną danych zebranych w poprzednich etapach. Wdrożono pierwsze algorytmy w środowisku testowym, porównując dane z sensorów z wynikami laboratoryjnymi. Etap ten stanowił kluczowy moment w walidacji modeli analitycznych oraz w ocenie spójności i stabilności systemu pomiarowego. Usprawniono też algorytmy firmware oraz aplikacji mobilnej spektrometru, co podwyższyło jakość i szybkość pomiaru. Wytworzony został również szczegółowy plan badawczy na kolejny sezon i przeprowadzono badania gleby w wyznaczonych punktach.

Etap 5 (04.2024–04.2025): Ostatni etap skupił się na finalizacji całego projektu, obejmując ostateczne pobieranie próbek, kompleksową analizę statystyczną oraz integrację modeli machine-learningowych z oprogramowaniem aparatury pomiarowej. W tym okresie opracowano finalny prototyp aplikacji umożliwiającej generowanie map zasobności roślin w azot oraz udoskonalono modele kalibracyjne. Całość działań zakończono przygotowaniem kompletnej dokumentacji technologicznej i operacyjnej, stanowiącej podstawę do wdrożenia innowacyjnych rozwiązań w gospodarstwach rolnych.

1. Etap 1: Przygotowanie operacyjne i organizacja badań (01.2023–04.2023)

1.1. Obudowy do prototypów wykonane metodą wtrysku

W ramach projektu opracowano model 3D obudowy urządzenia ScanSpectrum, który został dostosowany do wykonania formy wtryskowej. We współpracy z firmą Plastvision sp. z o.o. przeprowadzono liczne iteracje modelu, wprowadzając kolejne poprawki w oparciu o wymagania technologiczne oraz wnioski z testów. W celu weryfikacji poprawności projektu wykonano prototypowe obudowy metodą druku 3D. Po zakończeniu etapu testów firma Plastvision wprowadziła finalne korekty i przygotowała model formy wtryskowej przeznaczonej do masowej produkcji. Zaprojektowane obudowy zapewniają wysoką powtarzalność pomiarową pomiędzy egzemplarzami urządzenia, co ma kluczowe znaczenie w kontekście realizacji badań terenowych na dużą skalę.



Rys. 1.1.1 Model 3D obudowy spektrometru przygotowany przez zespół firmy QED.



SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO

Zespół QED na bieżąco monitorował postępy prac realizowanych przez firmę Plastvision. Skuteczny nadzór wymagał bezpośredniej komunikacji oraz regularnych wizyt u podwykonawcy. Po wielu iteracjach, obejmujących poprawki i uzgodnienia techniczne, ostateczny model został zatwierdzony i przekazany do realizacji jako gotowa forma wtryskowa.



Rys. 1.1.2. Forma wtryskowa wykonana przez firmę Plastvision.




Rys. 1.1.3. Pierwsze elementy obudowy wykonane metodą wtrysku.

1.2. Budowa i programowanie prototypów spektrometru

Zespół QED zbudował 10 prototypów urządzenia, instalując w obudowach wszystkie niezbędne komponenty: elementy optyczne, układy elektroniczne oraz moduły sterowania odpowiedzialne za działanie urządzenia i jego komunikację z aplikacją mobilną. W celu zapewnienia sprawnego zbierania danych spektralnych podczas eksperymentów terenowych, moduły sterowania zostały odpowiednio zaprogramowane – umożliwiały odbiór danych z sensorów optycznych oraz dwukierunkową komunikację z urządzeniami mobilnymi.



Rys. 1.2.1. Prace przygotowawcze do montażu elementów optycznych i elektronicznych w obudowach.



Rys. 1.2.2. Pierwsze prototypy urządzenia ScanSpectrum po montażu elementów optycznych i elektronicznych.



SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO

Założenia projektowe zostały opracowane na podstawie dyskusji prowadzonych w grupach fokusowych. Celem było ustalenie rodzaju danych, które będą zbierane, oraz określenie, które funkcje urządzenia muszą być zaimplementowane w firmware, a które po stronie aplikacji mobilnej. Efektem tych prac było stworzenie założeń umożliwiających szybką i zdalną modyfikację wielu parametrów aplikacji, co umożliwi łatwą aktualizację oprogramowania w przyszłości.

Założenia dotyczące firmware koncentrowały się głównie na obsłudze elektroniki wewnątrz urządzenia oraz protokołu komunikacji z aplikacją mobilną, z której będą przesyłane parametry dotyczące akwizycji obrazów spektralnych. Poprzez analizę znaleziono wiele kompatybilnych bibliotek i możliwości programistycznych. W drodze eliminacji wybrano protokół komunikacji Android Open Accessory jako najbardziej optymalny i zapewniający wysoką przepustowość, co jest istotne przy przesyłaniu dużych ilości danych. Dodatkowo wybrano kilka bibliotek języka Python do obsługi tego protokołu oraz innych aspektów elektronicznych głównego modułu sterowania.

Ostateczny wybór bibliotek oraz testy jednostkowe przeprowadzono na etapie programowania, gdzie sprawdzono skuteczność ich działania.

Aby sprostać wymaganiom projektowym, konieczne było wybranie odpowiedniego systemu operacyjnego, który potrafiłby obsłużyć interfejs sensora, zapewnić sprawną komunikację z urządzeniem mobilnym oraz szybkie i stabilne uruchomienie bez błędów. Przeprowadzono testy na różnych systemach Unixowych, które wymagały pewnych poprawek w jądrze napisanych w języku C++. Obsługa sensora oraz podtrzymywanie działania systemu zostały zaimplementowane w języku Python oraz przy użyciu skryptów bash, które okazały się być najszybszym i najbardziej efektywnym rozwiązaniem.

Wszystkie prace były dokładnie udokumentowane za pomocą systemu kontroli wersji GIT, który służył również do prowadzenia całej dokumentacji projektowej. Napisano testy oraz symulatory, które sprawdzały działanie kodu oraz interakcję z aplikacją mobilną.


Stworzono wygodne API, które można łatwo połączyć z aplikacją mobilną. Elementy tego API obejmowały: niezależne sterowanie źródłami światła, uruchamianie wykonania pomiaru, kontrolę parametrów pracy sensora, a także transfer danych i metadanych z urządzenia do bazy danych aplikacji.

Dzięki dokładnej dokumentacji w systemie kontroli wersji opartym na GIT, można będzie monitorować wersje i wszystkie zmiany zachodzące w kodzie podczas testów w terenie co pozwoli na szybką reakcję na wykryte problemy.



SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO

W celu przyspieszenia procesu produkcji funkcjonalnych prototypów urządzeń, firma QED opracowała rozwiązanie umożliwiające szybkie testowanie oprogramowania oraz wprowadzanie zmian w kodzie firmware. To rozwiązanie jest w stanie wygenerować kompletny obraz programu, który łatwo można wgrać na urządzenie docelowe. W tym celu zintegrowano i wykorzystano system Jenkins.



Rys. 1.2.3. Środowisko testujące kod i generujące obraz do wgrania do pamięci urządzenia.

1.3. Przygotowanie aplikacji mobilnej do badań

Na podstawie badań środowiskowych przeprowadzonych w grupach fokusowych oraz dostępnych statystyk, postanowiliśmy skoncentrować się w pierwszej kolejności na opracowaniu aplikacji na system Android, który dominuje na rynku urządzeń mobilnych w Polsce, stanowiąc ponad 80% udziału. Wspólnie z zespołem oraz partnerami ustaliliśmy wymagania projektowe dotyczące aplikacji mobilnej.

Aplikacja miała być zdolna do zbierania dokładnych danych spektralnych, ich normalizacji i kalibracji, aby były przydatne do analizy przez analityków oraz do uczenia maszynowego. Zdecydowaliśmy się na stworzenie modułu umożliwiającego przetłumaczenie danych z sensora na plik CSV, eksportujący dane spektralne w zakresie 350 - 1150 nm. Prace nad aplikacją wymagały bliskiej współpracy zespołu, zwłaszcza w obszarze komunikacji z urządzeniem oraz zagadnień związanych ze spektroskopią i jej zastosowaniem w agronomii.

Głównym celem docelowej aplikacji było rozpoznanie urządzenia prototypowego, nawiązanie z nim połączenia, przejście do trybu pomiarowego poprzez interfejs użytkownika, a następnie umożliwienie wykonania pomiaru za pomocą przycisku na urządzeniu. Stworzone zostały schematy działania oraz wireframe'y prezentujące funkcjonalności aplikacji w trybie badawczym.




SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO

W docelowej wersji aplikacji ukryty zostanie moduł wyświetlania danych spektralnych, zastępując go modulem prezentującym dane rolnicze, takie jak zawartość azotu, sucha masa, współczynniki stresu itp., po wprowadzeniu dodatkowych informacji dotyczących uprawy i rozpoznaniu danych geolokalizacyjnych. Realizacja tego planu wymaga doświadczenia z prac terenowych oraz analizy danych z roślin i modeli uczenia maszynowego, które pozwoliłyby na przeliczenie danych spektralnych na potrzebne dane rolnicze. Te prace będą wykonywane w kolejnych etapach projektu.

Po dokładnej analizie możliwości i funkcjonalności, jak również zasobów programistycznych, zdecydowaliśmy się na wykorzystanie środowiska Android Studio oraz języka programowania Kotlin do napisania aplikacji. W języku Kotlin dostępne są biblioteki umożliwiające obsługę protokołów komunikacyjnych, które zostały ustalone do użycia w firmware.

Zaprojektowaliśmy cały workflow wykonania aplikacji, podzielony na segmenty obejmujące interfejs użytkownika, komunikację z hardware, analizę danych oraz ich prezentację. Na tej podstawie ustaliliśmy kamienie milowe dotyczące budowy aplikacji.



Rys. 1.3.1. Mockup podstawowej funkcjonalności aplikacji.



SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO

Aby umożliwić zbieranie danych polowych przed pierwszą kampanią pomiarową, moduł pomiarowy musiał zostać ukończony. Programiści i analitycy z QED wspólnie opracowali gotowy prototyp aplikacji mobilnej, który był w stanie łączyć się z urządzeniem i pobierać dane spektralne do aplikacji w sposób umożliwiający ich wyeksportowanie i dalszą analizę.

Kierunek rozwoju aplikacji będzie ustalony poprzez konsultacje z potencjalnymi użytkownikami, w tym badaczami i rolnikami, którzy wezmą udział w badaniach. Ich opinie i uwagi podczas korzystania z naszego systemu będą kluczowe dla dalszego rozwoju i ostatecznego kształtu aplikacji mobilnej.



Rys. 1.3.2. Aplikacja mobilna wyświetlająca dane spektralne z prototypu ScanSpectrum.

Zespół wykonywał pomiary walidacyjne w środowisku zbliżonym do rzeczywistego w celu przetestowania funkcjonalności aplikacji oraz gotowości do prawdziwych pomiarów. Po kilku iteracjach poprawek, ustalono odpowiednie współczynniki kalibracyjne i stwierdzono gotowość do wykonywania prac badawczych od strony pomiarowej.



SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO

1.4. Wykonanie analiz przestrzennych i ustalenie zakresu prac badawczych

Jednym z kluczowych zadań było odpowiednie przygotowanie danych przestrzennych dotyczących operacji w ramach projektu. Konieczne było stworzenie map, które posłużą do określenia lokalizacji punktów poboru gleb i roślin. Dodatkowo te mapy będą stanowić podstawę do dalszych prac, w ramach których planujemy wygenerować mapy nawożenia na podstawie modeli uzyskanych za pomocą ScanSpectrum, zgodnych z urządzeniami rolniczymi do rozsiewania nawozów.

Przygotowanie map wymagało ścisłej współpracy z rolnikami. Konieczne było określenie granic działek, poznanie charakterystyki upraw oraz powiązanie danych z badań i działań agrotechnicznych z poprzednich lat, aby móc precyzyjnie zaplanować eksperyment.

Działki pod kontrolą rolników zostały ręcznie naniesione na mapę w środowisku QField, aby uzyskać uniwersalny format SHP. Następnie dane zostały wprowadzone do systemu, który współpracuje z danymi satelitarnymi, umożliwiając weryfikację działek za pomocą obrazu rzeczywistego oraz wprowadzenie innych danych dotyczących pól.

Dzięki współpracy z rolnikami oraz analizie dokumentów udało się uzyskać wszystkie potrzebne dane dotyczące działek ewidencyjnych w projekcie, płodozmianu oraz charakterystykę gleb z badań przeprowadzonych w poprzednich latach. Po tych działaniach dane dotyczące działek były gotowe do użycia przy wyznaczaniu punktów poboru gleb i roślin.

Zespół musiał opracować szczegółowy plan badań, aby jak najlepiej wykorzystać możliwości laboratorium OSCHR i zapewnić uzyskanie kompletnego zestawu danych potrzebnych do stworzenia modeli uczenia maszynowego. Właściwe planowanie miało kluczowe znaczenie dla zapewnienia zbioru danych, który byłby miarodajny i reprezentatywny, umożliwiając przewidywanie konkretnych parametrów na podstawie spektrum w różnych środowiskach w przyszłości.

Współpraca z rolnikami oraz analitykami zespołu doprowadziła do ustalenia optymalnych terminów pomiaru, które były zgodne z harmonogramami wysiewu i nawożenia. Dzięki temu możliwe było zaplanowanie pomiarów w najodpowiedniejszych momentach, co przyczyniło się do uzyskania najbardziej wartościowych danych.



SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO

Aby uzyskać odpowiednią różnorodność zawartości azotu lub suchej masy w roślinach ustaliliśmy następujące czynniki zmienności:

- Różny termin siewu
- Płodozmian
- Różne nawożenie na punktach (minimalne, średnie, wysokie)
- Różne rodzaje gleby
- Różne wyniki badań chemicznych gleby na zawartość azotu.
- Różne charakterystyczne współczynniki wegetacyjne z obrazów satelitarnych z poprzednich lat

Na podstawie dokładnych analiz danych z poprzednich lat, zespół wybrał zestaw pól oraz wyznaczył punkty w konkretnych lokalizacjach na tych polach, które charakteryzowały się wysoką zmiennością. Ponadto, ustalono zróżnicowane nawożenie na obszarach 12x12 metrów wokół wyznaczonych punktów badawczych.

Rolnicy zostali poinformowani o planach dotyczących wyznaczonych punktów, jednakże część z tych punktów musiała zostać przeniesiona ze względu na trudne warunki dostępu lub okresowe zalewanie terenów. Ostatecznie, zweryfikowane mapy zostały zaadaptowane do systemów QGIS i QField.

Przeprowadzono szkolenie dla badaczy i rolników z konsorcjum, na temat obsługi wspomnianych technologii, dzięki czemu byli oni gotowi na odnalezienie punktów oraz odpowiednie przeprowadzenie zabiegów czy późniejszych badań.




SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO



Rys. 1.4.1. Przykład wyznaczania punktów ze względu na typy gleby.



Rys. 1.4.2. Przykład analizy map wegetacyjnych z poprzednich lat.



Rys. 1.4.3. Wyznaczone punkty badawcze dla pszenicy na sezon pierwszy w rejonie Parczewskim.



Rys. 1.4.4. Instrukcja wyboru poziomu nawożenia na danych punktach.

Wyznaczono po 12 punktów dla upraw pszenicy, rzepaku i jęczmienia oraz 21 punktów dla kukurydzy w województwie łódzkim. Zaplanowane zostały 7 kampanii pomiarowych w sezonie pierwszym dla rzepaku, pszenicy i jęczmienia oraz 4 kampanie dla kukurydzy.



SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO

Species	Date	MIN (kg/ha)	MED (kg/ha)	MAX (kg/ha)
Rzepak	Drugi tydzień marca, 2023	200kg NH ₄ NO ₃ = 70 kg N pierwiastka	300kg NH ₄ NO ₃ =105 kg N pierwiastka	400kg NH ₄ NO ₃ = 140 kg N pierwiastka
Rzepak	Pierwszy tydzień kwietnia, 2023	10 kg of N pierwiastka z mocznika	15 kg of N pierwiastka z mocznika	30 kg of N pierwiastka z mocznika
Pszenica	Drugi tydzień marca, 2023	100kg NH ₄ NO ₃ = 35 kg of N pierwiastka	200kg NH ₄ NO ₃ = 70 kg of N pierwiastka	300kg NH ₄ NO ₃ = 105 kg of N pierwiastka
Pszenica	Trzeci tydzień kwietnia, 2023	45 kg of N pierwiastka z mocznika	50 kg of N pierwiastka z mocznika	65 kg of N pierwiastka z mocznika
Jęczmień	Ostatni tydzień Marca, 2023	60 kg of N pierwiastka z gnojowicy	60 kg of N pierwiastka z gnojowicy	60 kg of N pierwiastka z gnojowicy
Jęczmień	Pierwszy tydzień kwietnia	20 kg of N pierwiastka z mocznika	60 kg of N pierwiastka z mocznika	110 kg of N pierwiastka z mocznika

Tabela 1.4.1. Plany zmiennego nawożenia w pierwszym sezonie eksperymentu.

Poniżej przedstawiamy orientacyjny terminarz wykonywania badań ustalony z na podstawie spotkań naszych analityków z rolnikami oraz specjalistami z uczelni SGGW należącymi do konsorcjum. Terminy zaplanowano tak aby otrzymać odpowiedni zakres rozrzutu zawartości azotu i suchej masy w roślinach. Należy zwrócić uwagę, że rzeczywiste terminy mogą się znacząco różnić w zależności od warunków pogodowych oraz stopnia rozwoju uprawy, co w dobie obecnych zmian klimatycznych jest coraz trudniejsze do przewidzenia.



Rodzaj Badania	Uprawa	Numer kampanii pomiarowej	TERMIN-orientacyjny	kiedy- fazy BBCH
Badanie azotu w roślinach i analiza optyczna roślin	pszenica	1	20 kwietnia	29
		2	20 maja	39
		3	1 czerwca	49
		4	7 czerwca	59
		5	20 czerwca	69
		6	1 lipca	77
		7	20 lipca	89
	jęczmień	1	1 maja	29
		2	30 maja	39
		3	5 czerwca	49
		4	10 czerwca	59
		5	20 czerwca	69
		6	1 lipca	77
		7	25 lipca	89
	rzepak	1	20 września	13
		2	15 października	19
		3	10 lutego	21
		4	1 marca	29
		5	10 kwietnia	39
		6	30 kwietnia	59
		7	10 czerwca	79

Tabela 1.4.3. Terminarz dotyczący poboru prób roślin w eksperymencie dotyczącym azotu.



SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO

Sucha masa i analiza optyczna roślin	kukurydza	1	5 lipca	53
		2	20 lipca	65
		3	15 sierpnia	71
		4	15 września	85

Tabela 1.4.4. Terminarz dotyczący poboru prób roślin w eksperymencie dotyczącym suchej masy.

Podczas spotkań grup fokusowych dotyczących zabiegów precyzyjnych, zespół zgłębił działania związane z rolnictwem precyzyjnym. Analizowaliśmy protokoły komunikacyjne oraz formaty plików stosowane w programach maszyn rolniczych, takich jak precyzyjne rozsiewacze nawozów. Opracowaliśmy plan określenia odpowiedniej gęstości punktów pomiarowych, aby uzyskać miarodajne mapy nawożenia.

Ustaliliśmy także kluczowe parametry wejściowe, mające wpływ na późniejsze zabiegi precyzyjne, jak między innymi stosowane metody agrotechniczne. Konsultacje w tej kwestii pozwoliły nam wyznaczyć plany analizy danych oraz ich wpływu na wyniki, pozwolą również dokonać późniejszej kalibracji urządzeń w tym zakresie.

W trakcie spotkań ustaliliśmy, które parametry mające wpływ na precyzyjne zabiegi będą znane użytkownikowi końcowemu oraz w jaki sposób będzie mógł je wprowadzić do systemu aplikacji. Określiliśmy również kolejne kroki prac oraz kamienie milowe dotyczące dostosowania systemu do potrzeb użytkownika końcowego.




SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO

1.5. Przeprowadzenie badań glebowych

W celu precyzyjnego dostosowania dawek nawozowych do uzyskania odpowiedniej różnorodności na polach badawczych, badania glebowe zostały przeprowadzone z odpowiednim wyprzedzeniem czasowym, umożliwiającym uzyskanie i analizę wyników jeszcze przed rozpoczęciem procesu nawożenia.

Dokładne analizy pól przeprowadzone przez konsorcjantów oraz znajomość historii działek pozwoliły na wyznaczenie punktów poboru gleby. Celem tych badań było zebranie danych na bieżący oraz przyszły sezon, w którym planowane było ustalenie nowych lokalizacji punktów badawczych w zależności od wyników pomiarów gleby oraz nowego płodozmianu.



Rys. 1.5.1. Mapa punktów poboru gleb w rejonie Parczewskim, wyznaczona na podstawie dokładnych analiz danych historycznych, satelitarnych oraz danych dotyczących agrotechniki.



SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO

Za realizację kampanii pobierania próbek odpowiadała firma AgVisor z wieloletnim doświadczeniem w tym zakresie, posiadająca odpowiedni sprzęt do poboru gleby w sposób znormalizowany. Próbki glebowe zostały pobrane z ustalonych, geolokalizowanych punktów w dwóch standardowych przedziałach głębokości: warstwy ornej (0–30 cm) oraz warstwy podornej (30–60 cm). Takie podejście pozwala na ocenę zarówno dostępnych dla roślin zasobów azotu w strefie korzeniowej, jak i potencjalnych zasobów głębszych, które mogą być uruchamiane w dalszych fazach rozwoju.



Rys. 1.5.2. Zautomatyzowany zestaw do pobierania próbek glebowych zamontowany na pojeździe terenowym firmy AgVisor.



SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO

Punkty poboru gleby były oznaczane za pomocą fizycznych znaczników oraz za pomocą RTK GPS, co pozwoliło na zweryfikowanie zgodności lokalizacji rzeczywistych punktów poboru z wcześniej przygotowaną mapą.


Pobrane próbki zostały odpowiednio opisane, zabezpieczone i przekazane do certyfikowanego laboratorium, gdzie wykonano oznaczenia zawartości azotu mineralnego (N-NO₃ i N-NH₄).

Na podstawie przeprowadzonych analiz opracowany został szczegółowy raport zawierający interpretację wyników w kontekście lokalnych potrzeb nawożeniowych. Raport uwzględniał przestrzenne zróżnicowanie zawartości azotu w glebie i stanowił kluczowy element doboru strategii nawożenia azotowego na poszczególnych polach lub ich częściach.

Tabela wyników

Kod laboratoryjny próbki	Informacje od Klienta			Zawartość w mg/kg s.m. gleby		Zawartość Nmin w kg/ha ²⁾	Zawartość Nmin w kg/ha w warstwie 0-60 ²⁾	zasobność ¹⁾
	Warstwa cm	Oznaczenie próbki	Kategoria agronomiczna gleby	N-NO ₃	N-NH ₄			
GI/47/23	0-30	12	średnia	5,36	2,75	34,90	46,30	bardzo niska
GI/47/24	31-60	12		2,65	<1,00 ⁿ	11,40		
GI/47/25	0-30	13	średnia	2,63	4,30	29,80	29,80	bardzo niska
GI/47/26	31-60	13		<1,00 ⁿ	<1,00 ⁿ	0,00		
GI/47/27	0-30	14	średnia	1,28	3,39	20,10	20,10	bardzo niska
GI/47/28	31-60	14		<1,00 ⁿ	<1,00 ⁿ	0,00		
GI/47/29	0-30	15	średnia	<1,00 ⁿ	2,12	9,10	15,50	bardzo niska
GI/47/30	31-60	15		<1,00 ⁿ	1,48	6,40		
GI/47/31	0-30	16	średnia	<1,00 ⁿ	2,39	10,30	10,30	bardzo niska
GI/47/32	31-60	16		<1,00 ⁿ	<1,00 ⁿ	0,00		
GI/47/33	0-30	17	średnia	2,25	3,39	24,30	46,80	bardzo niska
GI/47/34	31-60	17		2,99	2,25	22,50		
GI/47/35	0-30	18	średnia	1,66	3,74	23,20	28,40	bardzo niska
GI/47/36	31-60	18		<1,00 ⁿ	1,22	5,20		
GI/47/37	0-30	19	średnia	3,72	2,20	25,50	33,40	bardzo niska
GI/47/38	31-60	19		1,83	<1,00 ⁿ	7,90		
GI/47/39	0-30	20	średnia	2,76	2,14	21,10	33,60	bardzo niska
GI/47/40	31-60	20		1,90	1,01	12,50		
GI/47/41	0-30	21	średnia	21,69	17,31	167,70	293,40	bardzo wysoka
GI/47/42	31-60	21		21,47	7,77	125,70		
GI/47/43	0-30	22	średnia	2,32	12,35	63,10	83,10	średnia
GI/47/44	31-60	22		1,38	3,27	20,00		
GI/47/45	0-30	23	średnia	2,15	3,14	22,70	30,10	bardzo niska
GI/47/46	31-60	23		1,73	<1,00 ⁿ	7,40		
GI/47/47	0-30	24	średnia	1,14	2,32	14,90	14,90	bardzo niska
GI/47/48	31-60	24		<1,00 ⁿ	<1,00 ⁿ	0,00		
GI/47/49	0-30	25	średnia	1,57	3,89	23,50	32,40	bardzo niska
GI/47/50	31-60	25		<1,00 ⁿ	2,07	8,90		
GI/47/51	0-30	26	średnia	1,73	4,85	28,30	34,80	bardzo niska
GI/47/52	31-60	26		<1,00 ⁿ	1,51	6,50		
GI/47/53	0-30	27	średnia	3,99	4,43	36,20	62,30	niska
GI/47/54	31-60	27		3,32	2,76	26,10		

Rys. 1.5.3. Wyciąg z raportu badań glebowych w sezonie 2023 - tabela.



Rys. 1.5.4. Wyciąg z raportu badań glebowych w sezonie 2023 - mapa.

1.6. Ustalenie taktyk analizy i gromadzenia danych

Na podstawie danych spektralnych zebranych podczas prac kalibracyjnych, programista Machine Learning ustalił strukturę danych oraz przygotował przykładowe dane testowe. Analizując publikacje naukowe, ustaliliśmy najbardziej optymalne metody przygotowania danych do uczenia maszynowego. Przetestowaliśmy szereg tych metod na przykładowych danych, a do ostatecznie ustalonych metod należą filtracja filtrem Savitzky-Golay, usunięcie linii bazowej za pomocą średniej dopasowanego wielomianu oraz wyciąganie pierwszej pochodnej z linii spektralnej. Wszystkie te techniki zostały skonsultowane ze specjalistami w tej dziedzinie. Testy na przykładowych danych potwierdziły, że te techniki przyczyniają się do ujednolicenia danych i redukcji błędów wynikających z kalibracji w różnych terminach i pod różnymi warunkami.

Przeprowadziliśmy również przegląd literatury dotyczącej technik analizy spektralnej za pomocą uczenia maszynowego oraz zbadaliśmy możliwości przetestowania różnych modeli na danych pochodzących ze ScanSpectrum. Jako potencjalnie użyteczne techniki wytypowaliśmy modelowanie PLSR (Partial Least Square Regression), PCR (Principal Component Regression), ET (Extra trees), RF (Random Forest) oraz SVR (Support Vector Regression). Z analizy literatury i naszej specjalistycznej wiedzy wynika, że różne modele mogą wykrywać różne właściwości w spektrum, dlatego zdecydowaliśmy się przeprowadzać analizy przy użyciu wielu modeli, a następnie wybierać ten, który najlepiej pasuje do naszych potrzeb.

Analitycy wraz z programistą Machine Learning przeanalizowali również format danych wykorzystywanych w OSCHR oraz zostali przeszkoleni z metodologii badawczej oraz czynników potencjalnie wpływających na błędy pomiaru w analizie chemicznej, które muszą zostać wzięte pod uwagę w przyszłych analizach.



SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO

Zostało przygotowane środowisko testowe w postaci szeregu skryptów w języku python, które docelowo będą porządkować dane, dopasowywać dane z laboratorium do danych spektralnych na podstawie numerów identyfikacyjnych, a następnie przeprowadzać analizy.

Zespół analityków ustalił, że wykonanie 15 skanów za pomocą urządzenia ScanSpectrum jest optymalną ilością, uwzględniającą zarówno czas potrzebny na ich wykonanie, jak i konieczność uśrednienia pomiarów z punktu geograficznego. Taka liczba pomiarów na punkt zapewni odpowiedni stosunek sygnału do szumu, co pozwoli uzyskać wymaganą rozdzielczość danych dla planowanych modeli.

Podczas prac badawczych istnieje duże ryzyko popełnienia pomyłek przez operatorów, takich jak błędy dotyczące kodów identyfikacyjnych, duplikowanie pomiarów lub pominięcie pomiarów. Podczas zebrania grup fokusowych zastanawialiśmy się, jak uniknąć tego rodzaju błędów podczas wielu kampanii pomiarowych z dużą ilością punktów i pomiarów. Ostatecznie, wynikiem naszych prac było zaplanowanie i integracja przez programistów QED użycia systemu ODK.

ODK to system umożliwiający szybkie i łatwe tworzenie formularzy w aplikacji mobilnej. Nasi programiści QED dokonali integracji systemu ODK z aplikacją ScanSpectrum. Dzięki temu, wypełniając formularz, operator może wybrać swoje dane identyfikacyjne, numer kampanii, numer punktu oraz badany gatunek. W tym samym formularzu można również przejść do wykonywania pomiarów za pomocą aplikacji ScanSpectrum. Wszystkie powiązane dane trafiają do specjalnie przygotowanej bazy danych na serwerze QED, dedykowanej do tego zadania.

	A	B	C	D	E	F	G	H	I	
1	name	type	label	hint	constraint	constraint_message	relevant	required	required_message	appearance
3	end	end								
4	today	today								
5	deviceid	deviceid								
6	subscriberid	subscriberid								
7	imei	imei								
8	username	username								
9	phonenumber	phonenumber								
10	enumerator	select_one enumerator_list	Data enumerator	Choose your name				true		
11	enumeratorOther	text	Name	Please specify your name	string-length() < 70	Your name is too long!	\$(enumerator)= 'other'			
12	species	select_one species_list	Species	Select the species you are analyzing				true		
13	campaign	select_one campaign_list	Campaign number	Enter the campaign number				true		
14	location	select_one location_list	Location code	Enter the integer study code assigned to this location				true		
15	OSCHR_code	calculate								
16	OSCHR_note	note	OSCHR code: \$(OSCHR_code)							
17	ss_data_multiple	begin_group	Multiple scans from ScanSpectrum							field-list
18	scan_1	file	ScanSpectrum #1	Take ScanSpectrum measurement #1				true		
19	scan_2	file	ScanSpectrum #2	Take ScanSpectrum measurement #2				true		
20	scan_3	file	ScanSpectrum #3	Take ScanSpectrum measurement #3				true		
21	scan_4	file	ScanSpectrum #4	Take ScanSpectrum measurement #4				true		
22	scan_5	file	ScanSpectrum #5	Take ScanSpectrum measurement #5				true		
23	scan_6	file	ScanSpectrum #6	Take ScanSpectrum measurement #6				true		
24	scan_7	file	ScanSpectrum #7	Take ScanSpectrum measurement #7				true		
25	scan_8	file	ScanSpectrum #8	Take ScanSpectrum measurement #8				true		
26	scan_9	file	ScanSpectrum #9	Take ScanSpectrum measurement #9				true		
27	scan_10	file	ScanSpectrum #10	Take ScanSpectrum measurement #10				true		
28	scan_11	file	ScanSpectrum #11	Take ScanSpectrum measurement #11				true		
29	scan_12	file	ScanSpectrum #12	Take ScanSpectrum measurement #12				true		
30	scan_13	file	ScanSpectrum #13	Take ScanSpectrum measurement #13				true		
31	scan_14	file	ScanSpectrum #14	Take ScanSpectrum measurement #14				true		
32	scan_15	file	ScanSpectrum #15	Take ScanSpectrum measurement #15				true		
33	ss_data_multiple	end_group								
34										
35										

Rys. 1.6.1. Schemat pliku wejściowego "XLS form" do systemu formularzy ODK wraz z integracją z systemem ScanSpectrum.



SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO

Dzięki temu rozwiązaniu, nasi analitycy mogą monitorować na bieżąco ilość i poprawność zbieranych danych w trakcie ich gromadzenia na polach badawczych. To pozwala nam skutecznie zapobiegać i korygować ewentualne błędy oraz zapewniać integralność i wiarygodność danych zebranych podczas kampanii pomiarowych.

[AcceptSampleFragment.kt](#)
[AcceptSampleViewModel.kt](#)
[example_xls_form.xlsx](#)
[IncorrectScanParametersFragment.kt](#)
[ODKScanActivity.kt](#)
[ODKScanViewModel.kt](#)
[README.md](#)

app/src/main/java/ai/qed/scanspectrum/odk/README.md

ScanSpectrum integration with ODK

ScanSpectrum supports integration with ODK Collect.

There are two ways ScanSpectrum with ODK Collect can be used:

- Populate a single field
- Populate multiple fields in a group with a single launch

Populate a single field

When only one field need to be populated with a single scan, then follow the instructions in the official [documentation](#).

In short:

- set the field type to `file`
- set the field appearance to the intent description with the `ex:` prefix

Populate multiple fields in a group

When there is a need to populate multiple fields with a single launch, then follow the instructions in the official [documentation](#).

In short:

- Create a group of fields with appearance set to `field-list`
- Add intent description in the group's `body::intent` column (note that the `ex:` prefix is omitted in this case)

ScanSpectrum also requires following:

- All fields in the group must be type of `file`
- `export_sample_names_prefix` and `export_samples_number` must be specified
- All field names must match following regex: `(export_sample_names_prefix)_(number)([a-zA-Z_0-9]*)?` where number is a number from 1 to `export_samples_number`.
- No two fields can have the same number
- There must be exactly `export_samples_number` fields in the group

For example: `scan_1`, `scan_2`, `scan_3` or `scan_1`, `scan_2_top`, `scan_3_bottom` are valid field names for `export_sample_names_prefix` set to `scan` and `export_samples_number` set to 3. `scan_1`, `scan_1_top_leaf`, `scan_2` are not valid inside one group.


Rys.1.6.2. Fragment dokumentacji technicznej dotyczącej integracji z systemem formularzy ODK.



SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO

Na podstawie ustaleń i analiz dotyczących całego procesu przeprowadzania badań oraz gromadzenia danych, szczegółowo opracowaliśmy schematy dataflow oraz struktury baz danych. Określiśmy odpowiednie formaty przechowywania plików na dedykowanych serwerach, zapewniając integralność i bezpieczeństwo danych.

Ustaliliśmy także procedury przydzielania dostępu do serwerów, które obejmują dane związane z ScanForm, ScanSpectrum oraz inne dane przechowywane w dedykowanych miejscach. Dzięki temu będziemy w stanie łatwo zidentyfikować, który badacz lub rolnik udostępnił dane, a w przypadku wystąpienia pomyłek będziemy mogli przeprowadzić dodatkowe szkolenia i zarządzać dostępem do danych w sposób kontrolowany i efektywny.




Rys. 1.6.3. Schemat przepływu danych dotyczący prac badawczych.

Analiza danych doprowadzi do identyfikacji istotnych korelacji między zawartością azotu w roślinach lub zawartością suchej masy a innymi parametrami. Na tej podstawie opracowane zostaną modele, które będą w stanie przewidywać te wartości na podstawie bezpośrednich pomiarów na polu. Modele te zostaną zaimplementowane w aplikacji mobilnej, co umożliwi generowanie map nawożenia oraz określenie optymalnych terminów zbioru na podstawie pomiarów z wielu punktów na polu.



SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO



Rys.1.6.4. Schemat dalszych prac dotyczących wdrożenia innowacji.

Podczas prac badawczych istotne jest zbieranie dodatkowych parametrów dotyczących uprawy, takich jak waga zebranej próby czy obsada, które mogą mieć istotne znaczenie przy późniejszych analizach danych. W planie badawczym uwzględniliśmy również wykorzystanie komercyjnych urządzeń referencyjnych do pomiaru wartości związanych z azotem i chlorofilem.

Aby zapewnić skuteczne zbieranie tych danych, opracowaliśmy papierowy formularz kompatybilny z systemem QED ScanForm. Formularz ten należy wypełniać podczas prowadzenia badań, a wyniki są przekazywane na serwer QED poprzez wykonanie zdjęcia za pomocą aplikacji QED ScanForm. Dzięki temu rozwiązaniu, eliminujemy konieczność ręcznego przepisywania wyników, co przyspiesza proces badawczy oraz minimalizuje ryzyko popełnienia błędów przez badaczy i utraty danych.

ARIMR: ScanSpectrum **Field Notebook**

Species	Wheat	Rape	Barley	Corn	Date of sampling DD/MM/YY	Campaign	BBCH code	Location	Plant count	Plant density	ScanSpectrum	N-tester	Chlorophyll	Wet mass: leaves	Wet mass: stalks	Wet mass: generatives	Initials	Discard
#1																		
#2																		
#3																		
#4																		
#5																		
#6																		
#7																		
#8																		
#9																		
#10																		
#11																		
#12																		
#13																		
#14																		
#15																		

INSTRUCTIONS

Filling out

- Cross an oval with an X.
- Use square boxes for numbers and letters.
- Write exactly one letter/digit in one box.
- Questions marked with an asterisk * are mandatory.

Correcting Mistakes

- When you make a mistake in, shade it and write the correct answer close to it. Below a mistake is corrected to "W".

ARIMR 1.1

Data Matrix ID here

Rys. 1.6.5. Formularz QED ScanForm przygotowany do zbierania danych terenowych.



System ScanForm, po wykonaniu zdjęcia za pomocą aplikacji mobilnej, automatycznie rozpoznaje tekst zawarty na papierowym formularzu i digitalizuje dane, dzięki czemu są one dostępne w formie cyfrowej bez konieczności ręcznego przepisywania. W celu zapewnienia poprawności przetwarzania danych, proces jest monitorowany na bieżąco przez weryfikatorów ludzkich oraz zaawansowane algorytmy widzenia maszynowego.

1.7. Metodologia pobierania próbek i pierwsza kampania pomiarowa

W ścisłej współpracy z naszymi konsorcjantami opracowaliśmy kompleksową metodologię pobierania próbek. Kadra naukowa przeprowadziła szczegółowe szkolenie dla zespołu QED i rolników, obejmujące metody prawidłowego pobierania, przechowywania i transportowania próbek roślinnych, aby zapewnić jak najmniejsze zakłócenia w procesie analitycznym w laboratorium OSCHR.

Wspólnie opracowaliśmy również szczegółową instrukcję dotyczącą pobierania próbek i przeprowadzania badań, wykorzystując prototypy spektrofotometru ScanSpectrum oraz urządzeń referencyjnych. Dzięki temu podejściu zapewniamy spójność i wysoką jakość danych zbieranych podczas badań terenowych, co jest kluczowe dla skutecznej analizy i interpretacji wyników.

Instrukcja wykonywania pomiarów w projekcie "ScanSpectrum - innowacja w Polskim rolnictwie"



Wstęp	1
Plan eksperymentu	2
Model azotowy	2
Model sucha masa	6
Taktyka zbierania danych i oznaczenia	6
Przed wyruszeniem w pole	7
Formularz ScanForm	8
Wstęp	8
Ogólne zasady wypełniania ScanForm	9
Skonowanie ScanForm	10
Opis czynności podczas pomiarów	12
Obliczenie obsady i pobór roślin do OSCHR	12
Pomiar N-Testerem	15
Pomiar chlorofilomierzem	16
Skonowanie ScanSpectrum	17

Podział próbek do OSCHR	17
Ważenie	17
Pomiary po żniwach	18
Pomiar ziarna przy pomocy ScanSpectrum	18
Pomiar zmielonego ziarna przy pomocy ScanSpectrum	20
Pomiar słomy przy pomocy ScanSpectrum	22

1. Należy znaleźć 2 metry bieżące dwóch reprezentatywnych rzędów, to znaczy że rośliny w tym rzędzie muszą reprezentować większy obszar wokół punktu poboru. Nie wybieramy najlepiej czy najgorzej wyglądających rzędów. Staramy się ocenić obszar do kilkunastu metrów wokół punktu w każdym kierunku i znaleźć rzędy które są adekwatne.

12

2. Oznaczamy 2 metry bieżące za pomocą znaczników wbitych w ziemię między rzędami, z których będziemy pobierać próby. Zaznaczamy początek, środek i koniec.

3. W przypadku młodych roślin: Odkopujemy rośliny z jednego z wybranych metrów łopatką, głęboko - tak aby nie uszkodzić korzeni. Gdy rośliny są starsze (od BBCH 49) można ucinąć je przy samym korzeniu. W przypadku młodych roślin podkopywanie jest ważne aby nie pomylić ilości roślin w jednym punkcie oraz aby zmniejszyć błąd pomiarowy ilości masy na ilość roślin (obcięty fragment który nie jest korzeniem dla młodej rośliny ma znaczenie)



Rys. 1.7.1. Przykładowe wyciągi z instrukcji wykonywania pomiarów w projekcie badawczym.



SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO

Instrukcja zawiera opisy przygotowania się przed każdą kampanią pomiarową, narzędzia i oznaczenia jakie należy zabrać, zawiera instrukcję korzystania ze spektrometru ScanSpectrum oraz urządzeń referencyjnych jak i instrukcje znajdowania punktów w terenie przy użyciu aplikacji QField. Opisaliśmy również instrukcję obsługi systemu ODK oraz ScanForm. W instrukcji zawarto zdjęcia i porady na temat liczenia obsady i parametrów roślin.



Rys. 1.7.2. Zespół badawczy podczas wykonywania pierwszych prac badawczych na uprawach pszenicy.



Rys. 1.7.3. Wykonywanie pomiarów za pomocą prototypów ScanSpectrum i urządzeń referencyjnych.



SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO

Dzięki dokładnym instrukcjom i szkoleniom zespół badawczy przyswoił wiedzę na temat korzystania z wszystkich technologii wymaganych do poprawnego zbierania danych. Wiedza ta została zweryfikowana podczas pierwszej kampanii pomiarowej. Wnioski badaczy i naukowców po pierwszej kampanii przyczyniły się do wdrożenia poprawek i aktualizacji w instrukcji oraz kilku elementach procesu.

ScanSpectrum [ARIMR] mobile application interface showing the data entry process. The screen is divided into three main sections: Species, Campaign number, and Location code. The Species section has radio buttons for Wheat, Rape, Barley, and Corn. The Campaign number section has radio buttons for numbers 1 through 7. The Location code section has radio buttons for Location 01 through Location 11. A 'Verify sample' screen is also shown, displaying a spectral graph and NDVI: 0.846.

Rys. 1.7.4. Przykład kolejnych kroków wypełniania formularzy ODK.

Dane z pierwszej kampanii pomiarowej były na bieżąco monitorowane, ich poprawność była sprawdzana przez zespół, aby wcześnie wykrywać błędy - chociażby związane z możliwością rozkalibrowania się urządzeń pomiarowych.

ScanSpectrum [ARIMR] - Wheat, Barley, Rape

213 submissions

SUMMARY FORM DATA SETTINGS

1 - 213 of 213 results.

Species	Campaign nu...	Location code	OSCHR_code	OSCHR code: ...	Multiple scan...	ScanSpectru...	Multiple scan...	ScanSper
Wheat	1	Location 15	1115		16989444818...		16989444818...	
Wheat	1	Location 13	1113		16989441996...		16989441996...	
Wheat	1	Location 17	1117		16989438319...		16989438319...	
Wheat	1	Location 07	1107		16989434030...		16989434030...	
Wheat	1	Location 01	1101		16989434791...		16989434791...	
Wheat	1	Location 04	1104		16989422261...		16989422261...	
Rape	2	Location 05	2205		16989422732...		16989422733...	
Rape	2	Location 01	2201		16989418194...		16989418194...	
Rape	2	Location 09	2209		16989415816...		16989415817...	
Wheat	1	Location 08	1108		16989414801...		16989414801...	

Rys. 1.7.5. Zrzut ekranu z serwera QED zawierającego dane spektralne powiązane z identyfikacją.



SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO

Dane na temat upraw były wypełniane na bieżąco wraz ze zbieraniem roślin. Rośliny były liczone, ważone i mierzone urządzeniami referencyjnymi. Po wypełnieniu całego arkusza, badacz skanował go smartfonem z aplikacją mobilną ScanForm tak aby natychmiast trafiły na serwery QED, gdzie dane były również weryfikowane przez algorytmy i kadrę weryfikatorów.

The screenshot shows the ScanForm application interface. On the left, there is a sidebar with navigation options: Hide minimap, Switch minimap position, Verify all, Show all groups, Report issues, Help, Next entry, Delete entry, and Show details. The main area displays a data entry form for plant measurements. The form is organized into columns and rows. The columns are labeled: BCH code, Location, Plant count, Plant density, ScanSpectrum, N-tester, Chlorophyll, Wet mass: leaves, Wet mass: stalks, Wet mass: generatives, and Initials. The rows represent individual plant samples. Each row contains handwritten data for each field. For example, the first row shows BCH code 15, Location 04, Plant count 26, Plant density 52, ScanSpectrum 441, N-tester 169, Chlorophyll 1363, Wet mass: leaves 1363, Wet mass: stalks 1363, Wet mass: generatives 1363, and Initials 95. The form also includes a QR code at the bottom right and a 'Discard' button for each row.

Rys. 1.7.6. Zrzut ekranu z wypełnionego formularza ScanForm na serwerze QED.

Pierwsza kampania pomiarowa przebiegła pomyślnie, zebrane rośliny zostały zabezpieczone i niezwłocznie przewiezione do okręgowej stacji chemiczno rolniczej która będzie badać jej skład chemiczny.

1.8. Podsumowanie

Etap pierwszy umożliwił wykonanie prototypów urządzenia pomiarowego ScanSpectrum, które są wystarczające do przeprowadzenia badań polowych. Oprócz zbierania danych spektralnych, nasze urządzenie będzie poddane walidacji w realnym środowisku z udziałem rzeczywistych potencjalnych użytkowników docelowych. Każdy z badaczy będzie zaangażowany w proces, pytany o opinie na temat użytkowania urządzenia oraz możliwych ulepszeń, zarówno jeśli chodzi o sam spektrometr, jak i system zbierania i analizy danych. Dodatkowo, bliska komunikacja z rolnikami pozwoli na dostosowanie docelowego interfejsu do ich specyficznych potrzeb.

Stworzenie zintegrowanego systemu do zbierania i analizy danych ma na celu usprawnienie prac badawczych na kolejnych etapach. Dzięki temu będziemy mogli skoncentrować się na szczegółowych analizach, usprawnieniach systemu oraz planowaniu dalszych działań.



SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO

2. Etap 2: Rozszerzenie działań badawczych i rozwój modeli analitycznych (05.2023–08.2023)

2.1. Prace polowe

Pobór próbek pszenicy, rzepaku i jęczmienia był kontynuowany w okresie od maja do lipca. Próbki były dzielone na części gdy faza rozwojowa wskazywała na konieczność podziału (łodygi, liście oraz części generatywne) w celu precyzyjnej analizy zawartości azotu w różnych organach roślinnych. Podział ten pozwalał na zrozumienie, jak pierwiastek ten jest dystrybuowany w roślinie w zależności od fazy rozwojowej (BBCH). Liście, jako główne miejsce fotosyntezy, często zawierają najwyższe stężenie azotu w fazach wegetatywnych, podczas gdy łodygi i części generatywne (np. kłosa) mogą wykazywać różnice w zawartości azotu w miarę dojrzewania roślin. Dzięki temu podziałowi możliwe było nie tylko kalibrowanie spektrofotometru pod kątem pomiaru azotu w różnych częściach roślin, ale także zbadanie, jak zmienia się efektywność wykorzystania azotu przez rośliny w poszczególnych fazach wzrostu, co ma istotne znaczenie dla optymalizacji nawożenia i zwiększenia plonów.


Podział ręczny roślin na części wykonywany był po zebraniu obrazów spektralnych, w laboratorium po pobraniu materiału roślinnego aby uniknąć wpływu stresu wynikającego z podziału na spektrum odbiciowe. Części roślin były pakowane oddzielnie, oznaczone zgodnie z ustalonym kodem identyfikacyjnym i przewiezione do Okręgowej Stacji Chemiczno Rolniczej.



Rys. 2.1.1. Pobór próbek rzepaku w fazie kwitnienia.



Rys. 2.1.2. Zespół badaczy wykonujący prace polowe związane z poborem prób roślinnych.



Rys. 2.1.3. Zespół badawczy podczas dzielenia roślin na liście, łodygi i części generatywne w celu przygotowania próbek laboratoryjnych.

Pobór próbek kukurydzy przeprowadzono w kluczowych fazach rozwojowych roślin, określonych na podstawie skali BBCH, aby umożliwić nie tylko ocenę aktualnej zawartości suchej masy, ale także estymację optymalnego terminu zbioru na kiszonkę w przyszłości. Próbkę zbierano w fazach BBCH 53 (początek wyrzucania wiech), BBCH 65 (pełne kwitnienie), BBCH 71 (początek dojrzewania ziarna) oraz BBCH 85 (dojrzałość mleczno-woskowa). W każdym terminie pobierano rośliny w okolicach wyznaczonych wcześniej punktów na polach testowych, starając się zachować reprezentatywność prób. Pobierano po 3 rośliny z punktu, ścinano je na wysokości około 5 cm nad ziemią. Próbkę ważono od razu po ścięciu. Po wykonaniu pomiarów spektralnych były one pakowane i wysyłane do laboratorium OSCHR w celu precyzyjnego laboratoryjnego wysuszenia i określenia suchej masy. Dzięki systematycznemu poborowi próbek w kluczowych fazach możliwe było opracowanie modelu wzrostu kukurydzy, który pozwala na prognozowanie optymalnego terminu zbioru na kiszonkę w kolejnych sezonach, uwzględniając warunki pogodowe i tempo akumulacji suchej masy.



SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO



Rys. 2.1.4. Pomiar masy próbki kukurydzy po zebraniu.

W celu kontroli danych i weryfikacji, próbki były ważone powtórnie tuż przed wysyłką, oraz zaraz po przyjęciu do laboratorium.



Rys. 2.1.5. Pomiary spektralne liści kukurydzy za pomocą ScanSpectrum i urządzeń referencyjnych.



SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO

2.2. Opracowanie danych

Wyniki z Okręgowych Stacji Chemiczno-Rolniczych były wysyłane do firmy w formacie papierowych sprawozdań badawczych, żadna ze stacji nie zgodziła się na przesyłanie wyników w formie cyfrowej.

Zleceniodawca: **QED POLAND SP. Z O.O.**
Adres: **ul. Jana III Sobieskiego 102A/30**
00-764 Warszawa

Sprawozdanie z badań nr RX/1/2023

do umowy/zlecenia nr RX/1/2023

- Obiekt badany: materiał roślinny.
- Cel analizy: do celów własnych.
- Próbkę pobrane przez zleceniodawcę według własnej metodyki.
- Próbkę dostarczył kurier.
- Stan próbek spełnia kryterium przydatności próbek do badań.
- Data przyjęcia próbek do badania: 2023-04-21; Badania wykonano w dniach: 2023-04-21 do 2023-05-09.
- Wyniki odnoszą się wyłącznie do otrzymanych i badanych próbek.
- Bez pisemnej zgody laboratorium sprawozdanie nie może być powielane inaczej, jak tylko w całości.
- Informacje od klienta: zleceniodawca, dane teleadresowe, cel analizy, obiekt badany, dane dotyczące pobierania próbek.

Tabela wyników

Kod literowo- cyfrowy próbki	Oznaczenie próbki przez Klienta	Zawartość	
		Masa próbki (przed suszeniem)	Masa próbki (po suszeniu)
RX/1/1	1	105,7	22,4
RX/1/2	2	181,4	35,4
RX/1/3	3	142,3	29,6
RX/1/4	4	187,5	43,8
RX/1/5	5	233,0	48,4
RX/1/6	6	160,6	40,0
RX/1/7	7	206,2	45,9

Rys. 2.2.1. Format przesyłanych danych dotyczących suchej masy próbki.



SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO

Zleceniodawca: QED POLAND SP. Z O.O.
Adres: ul. Jana III Sobieskiego 102A/30
00-764 Warszawa

Sprawozdanie z badań nr RX/1/2023/U1

do umowy/zlecenia nr RX/1/2023

- Obiekt badany: materiał roślinny.
- Cel analizy: do celów własnych.
- Próbkę pobrane przez zleceniodawcę według własnej metodyki.
- Próbkę dostarczył kurier.
- Stan próbek spełnia kryterium przydatności próbek do badań.
- Data przyjęcia próbek do badania: 2023-04-21; Badania wykonano w dniach: 2023-04-21 do 2023-06-20.
- Wyniki odnoszą się wyłącznie do otrzymanych i badanych próbek.
- Bez pisemnej zgody laboratorium sprawozdanie nie może być powielane inaczej, jak tylko w całości.
- Informacje od klienta: zleceniodawca, dane teleadresowe, cel analizy, obiekt badany, dane dotyczące pobierania próbek.

Tabela wyników




Kod literowo- cyfrowy próbki	Oznaczenie próbki przez Klienta	Zawartość Azot ogólny Kjeldahla
RX/1/1	1	3,23
RX/1/2	2	4,12
RX/1/3	3	4,05
RX/1/4	4	3,24
RX/1/5	5	3,76
RX/1/6	6	2,65
RX/1/7	7	3,58

Rys. 2.2.2. Format przesyłanych danych dotyczących azotu ogólnego w biomase roślinnej.


OSCHR sample number	Roślina	masa po zebraniu (g)	masa po suszeniu na powietrzu - OSCHR (g)	masa po wysuszeniu w piecu - OSCHR (g)	Procent masy po wysuszeniu (%)	Procent suchej masy rzeczywistej	AZOT (%) suchej masy	FOSFOR (%) suchej masy	POTAS (%) suchej masy
11011	pszenica	123	105.7	22.4	21.2	18%	3.23	0.49	3.43
11021	pszenica	221	181.4	35.4	19.5	16%	4.12	0.57	3.61
11031	pszenica	169	142.3	29.6	20.8	18%	4.05	0.54	2.92
11041	pszenica	212	187.5	43.8	23.4	21%	3.24	0.47	2.73
11051	pszenica	266	233	48.4	20.8	18%	3.76	0.43	3.1
11061	pszenica	187	160.6	40	24.9	21%	2.65	0.42	2.78
11071	pszenica	242	206.2	45.9	22.3	19%	3.58	0.55	2.81
11081	pszenica	246	223.2	46.5	20.8	19%	3.7	0.52	3.47

Rys. 2.2.3. Dane po digitalizacji ręcznej.

Każdorazowo po otrzymaniu danych, zespół analityków dokonywał analizy statystycznej wyników, jednocześnie sprawdzając warunki brzegowe. Zliczanie błędów standardowych, przygotowywanie histogramów i rozpisywanie funkcji sprawdzających warunki brzegowe pozwoliło na odpowiednią weryfikację danych i filtracje podejrzanych wyników. Wszystkie podejrzane wyniki były wyjaśniane z okręgowymi stacjami chemiczno rolniczymi od których pochodziły. W razie potrzeby, w zależności od formatu otrzymanych wyników, dane na temat makroelementów były przeliczane z % powietrznie suchej masy na % suchej masy całkowitej.



Rys. 2.2.4. Prezentacja dystrybucji azotu roślinnego w zależności od punktu, kampanii oraz części rośliny.



Rys. 2.2.5. Rozkład azotu w roślinach w zależności od kampanii. Wykres pokazuje że odpowiednio dobrano warunki upraw aby uzyskać szerokie i równomierne zakresy zawartości azotu.


2.3. Wstępne analizy danych spektralnych

Wstępne analizy danych spektralnych obejmowały przetworzenie widm odbiciowych liści w zakresie 400–1050 nm, które następnie sparowano z danymi dotyczącymi zawartości azotu dostarczonymi przez OSCHR Lublin. W widmie odbiciowym liści kluczowe zakresy spektralne związane z zawartością azotu to:


- 500–550 nm: Obszar związany z absorpcją chlorofilu, gdzie niskie odbicie wskazuje na wysoką zawartość chlorofilu, a tym samym potencjalnie wyższą zawartość azotu.
- 650–700 nm: Granica czerwieni (red edge), która jest silnie skorelowana z zawartością chlorofilu i azotu, ponieważ zmiany w absorpcji w tym zakresie są wrażliwe na zmiany w kondycji fotosyntetycznej roślin.
- 700–750 nm: Obszar przejścia między absorpcją chlorofilu a odbiciem w bliskiej podczerwieni (NIR), gdzie kształt krzywej odbicia jest silnie zależny od struktury liścia i zawartości azotu.
- 900–1050 nm: Zakres NIR, w którym odbicie jest związane z zawartością wody i strukturą tkanki liścia, pośrednio wpływającymi na zawartość azotu.



Spectral reflectance of wheat leaves, range 420-1050 nm,
colored by nitrogen percentage



Rys. 2.3.1. Prezentacja spektrów odbiciowych liści pszenicy pokolorowana po zawartości azotu, na wykresie widoczne są gradienty wskazujące na korelację zawartości azotu ze spektrum odbiciowym.




Rys. 2.3.2. Zmienność uśrednionych spektrów pszenicy w zależności od kampanii pomiarowej, widoczny jest wzrost zawartości barwnika - chlorofilu wraz z kolejnymi kampaniami oraz zmiany w strukturze komórkowej liści w zakresie podczerwieni.



SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO


Przetestowano różne metody preprocessingu (wstępnej obróbki) linii spektralnej aby ułatwić późniejsze analizy danych. Nauczanie maszynowe przy tak dużej ilości punktów pomiarowych sprowadza się do automatycznego wykrycia najbardziej znaczących obszarów spektrum i redukcji wymiarów do momentu kiedy otrzymujemy model predykcyjny zwracający tylko jeden parametr. Do przetestowanych metod należały metody stosowane szeroko w literaturze dotyczącej zagadnienia obróbki danych spektralnych:

- Filtr Savitzky'ego-Golaya: Wygładzenie widm w celu redukcji szumów przy zachowaniu kształtu krzywej spektralnej.
- Usunięcie linii bazowej: Eliminacja efektów tła, takich jak rozpraszanie światła, które mogły zakłócać interpretację danych.
- Pierwsza pochodna: Transformacja widm w celu uwydatnienia subtelnych zmian w krzywych odbicia, co pozwoliło na lepsze uchwycenie zależności między sygnałem spektralnym a zawartością azotu.



Rys. 2.3.3. Przykład danych spektralnych dla wszystkich roślin przed i po preprocessingu.

Na podstawie przetworzonych danych spektralnych zbudowano model regresji uniwersalny dla wszystkich typów badanych roślin, który wykazał współczynnik determinacji $R^2 = 0,75$ oraz średni błąd bezwzględny $MAE = 0,35$ dla $N = 167$ próbek. Wartość R^2 na poziomie 0,75 wskazuje na korelację między sygnałem spektralnym a zawartością azotu, co potwierdza, że zastosowane zakresy spektralne i techniki preprocessingu były skuteczne. $MAE = 0,35$ oznacza, że średni błąd predykcji zawartości azotu wynosi 0,35% zawartości N w przeliczeniu na suchą masę, co jest wynikiem satysfakcjonującym na tym etapie, biorąc pod uwagę złożoność próbek roślinnych.



Rys. 2.3.4. Pierwsze wyniki modelu testowy korelacji spektrum odbiciowego z zawartością azotu w roślinach.

Zespół analityków będzie prowadził dalsze analizy dotyczące testów siatek konfiguracji hiperparametrów modeli, testowanie różnych modeli predykcyjnych ale również doskonalenie technik preprocessingu odpowiadających najlepiej uzyskanemu typowi danych. Zespół skupi się również na analizie migracji azotu w roślinie, korelacji spektrów z konkretnymi częściami rośliny oraz modelach dostosowanych dla każdej rośliny z osobna, które teoretycznie powinny wykazać silniejsze korelacje.

2.4. Analizy przestrzenne i mapy nawożenia

Podczas kampanii pomiarowych rejestrowano również obrazy spektralne w punktach na polu, w których nie wykonywano analiz chemicznych. Na podstawie danych z wcześniej oznaczonych próbek opracowano wstępne modele spektralne, które następnie zastosowano do estymacji zawartości azotu w licznych punktach pomiarowych na całym polu. Dzięki temu możliwe było wygenerowanie przestrzennej siatki danych, przedstawiającej rozkład azotu w roślinności z wysoką rozdzielczością przestrzenną.



Rys. 2.4.1. Punkty w których wykonane zostały pomiary spektrometrem podczas wegetacji, pokolorowane po wyniku zawartości azotu z wstępnego modelu predykcyjnego, ciemniejsze kolory oznaczają wyższe stężenie azotu, jaśniejsze - niższe.

Przykład dla tych samych pól, już na tym etapie widać że podejście wykorzystujące bardzo tani pomiar spektralny jest znacznie bardziej efektywne w wykonywaniu map azotowych niż pomiar za pomocą metod chemicznych w laboratorium. Wyniki z pomiaru spektralnego będą otrzymywane natychmiast po pomiarze, a koszt wykonania jednego pomiaru wymaga jedynie poświęcenia czasu rolnika lub badacza. Podczas gdy pojedynczy pomiar spektralny trwa kilka sekund, wyniki z jednego punktu zbadane przez laboratorium docierały do nas w przeciągu 4 do 8 tygodni.




Rys. 2.4.2. Porównanie ilości punktów zebranych do analizy chemicznej z ilością punktów pomiarowych możliwych do osiągnięcia analizą optyczną.




SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO

Przykładowe obserwacje dotyczące zmienności nawożenia na punktach i zawartości azotu z modeli predykcyjnych potwierdzają skuteczność pomiaru spektralnego.



Rys. 2.4.3. Po lewej stronie widzimy punkty (12x12m) w których zastosowana była maksymalna i minimalna dawka ustalonego nawożenia w obrębie tego samego pola. Po prawej stronie punkty w których wykonany został pomiar spektralny w trakcie wegetacji pokolorowane w zależności od wartości predykcji azotu roślinnego oparte na wstępnych modelach regresji, kolor żółty - wysoka zawartość, kolor ciemnoniebieski - niska zawartość.

Odpowiednie zagęszczenie punktów pomiarowych na polu i zastosowanie technik uśredniania, pozwala na wykonanie ciągłych map dotyczących całego pola, oraz wyznaczenie sektorów w których należy zmienić dawkę nawozową.



Rys. 2.4.4. Pierwsze eksperymenty dotyczące uśredniania wyników pomiarów azotu widoczny jest podział na sektory o niskiej i wysokiej zawartości na podstawie której można ustalić dawki zmiennego nawożenia.



SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO

2.5. Analizy mapy plonów

Pod koniec okresu wegetacji, za pomocą urządzenia ScanSpectrum wykonano również mapy spektralne działek objętych projektem. Na ich podstawie wytypowano punkty na polach, w których powinny zostać przeprowadzone skany w kolejnych etapach badań. Celem było umożliwienie późniejszej weryfikacji dokładności generowanych map zawartości azotu oraz ocena możliwości ich zastosowania w szerszej skali przestrzennej.



Rys. 2.5.1. Przykładowy wycinek mapy podczas zbierania danych spektralno przestrzennych. Każdy punkt zawiera 15 skanów roślin na obszarze 25m².

Zostały przeanalizowane dane przestrzenne i spektralne, przygotowując je do dalszych analiz związanych z tworzeniem i weryfikacją próbnych map azotowych oraz powiązaniem danych spektralnych z pola, uzyskanych za pomocą ScanSpectrum, z danymi spektralnymi z kombajnu wyposażonego w czujnik NIR podczas zbiorów.




SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO

start	end	today	deviceid	subscriberimei	Species	_Take a	_Take a	ScanSpe	ScanSpe	ScanSpe	ScanSpe	ScanSpe
2023-07-	2023-07-	2023-07-0	collect:DStkCLzf2UGI3kXz		Winter Barley	51.6475	22.8811	1688803	1688803	1688803	1688803	1688803
2023-07-	2023-07-	2023-07-0	collect:DStkCLzf2UGI3kXz		Winter Barley	51.6477	22.8822	1688803	1688803	1688803	1688803	1688803
2023-07-	2023-07-	2023-07-0	collect:DStkCLzf2UGI3kXz		Winter Barley	51.6478	22.8838	1688804	1688804	1688804	1688804	1688804
2023-07-	2023-07-	2023-07-0	collect:DStkCLzf2UGI3kXz		Winter Barley	51.6483	22.8850	1688804	1688804	1688804	1688804	1688804
2023-07-	2023-07-	2023-07-0	collect:DStkCLzf2UGI3kXz		Winter Barley	51.6479	22.8858	1688804	1688804	1688804	1688804	1688804
2023-07-	2023-07-	2023-07-0	collect:DStkCLzf2UGI3kXz		Winter Barley	51.6477	22.8861	1688804	1688804	1688804	1688804	1688804
2023-07-	2023-07-	2023-07-0	collect:DStkCLzf2UGI3kXz		Winter Barley	51.6474	22.8868	1688804	1688804	1688804	1688804	1688804
2023-07-	2023-07-	2023-07-0	collect:DStkCLzf2UGI3kXz		Winter Barley	51.6468	22.8880	1688805	1688805	1688805	1688805	1688805
2023-07-	2023-07-	2023-07-0	collect:DStkCLzf2UGI3kXz		Winter Barley	51.6478	22.8877	1688805	1688805	1688805	1688805	1688805
2023-07-	2023-07-	2023-07-0	collect:DStkCLzf2UGI3kXz		Winter Barley	51.6483	22.8883	1688805	1688805	1688805	1688805	1688805
2023-07-	2023-07-	2023-07-0	collect:DStkCLzf2UGI3kXz		Winter Barley	51.6488	22.8888	1688805	1688805	1688805	1688805	1688805
2023-07-	2023-07-	2023-07-0	collect:DStkCLzf2UGI3kXz		Winter Barley	51.6494	22.8872	1688806	1688806	1688806	1688806	1688806
2023-07-	2023-07-	2023-07-0	collect:DStkCLzf2UGI3kXz		Winter Barley	51.6488	22.8864	1688806	1688806	1688806	1688806	1688806
2023-07-	2023-07-	2023-07-0	collect:DStkCLzf2UGI3kXz		Winter Barley	51.6491	22.8854	1688806	1688806	1688806	1688806	1688806
2023-07-	2023-07-	2023-07-0	collect:DStkCLzf2UGI3kXz		Winter Barley	51.6489	22.8838	1688806	1688806	1688806	1688806	1688806
2023-07-	2023-07-	2023-07-0	collect:DStkCLzf2UGI3kXz		Winter Barley	51.6487	22.8825	1688807	1688807	1688807	1688807	1688807

Rys. 2.5.2. Filtrowane dane spektralne przypisane do punktów geograficznych przygotowane do dalszych analiz po zbiorach.

Parametry plonu są kluczowymi danymi z punktu widzenia rolnika, ponieważ bezpośrednio wpływają na jakość produkowanej żywności, a co za tym idzie, na korzyści ekonomiczne. Dla projektu ScanSpectrum istotne jest, aby korzystanie z urządzenia do budowania map azotowych czy pomiarów suchej masy w kukurydzy ostatecznie przynosiło wymierne korzyści. Precyzyjne pomiary spektralne na różnych etapach rozwoju roślin mają skutkować dokładnymi wskazówkami dotyczącymi nawożenia w celu zwiększenia lub wyrównania plonu oraz stosowania zabiegów precyzyjnych, na przykład po wykryciu stresów związanych z chorobami.

Do precyzyjnego pomiaru plonów został wykorzystany nowoczesny kombajn z analizatorem NIR firmy Dinamica Generale, sprzężony z systemem New Holland. System ten pozwala na monitorowanie zbieranego ziarna w czasie rzeczywistym i generowanie map, z których można odczytać masę plonu, wilgotność, a nawet zawartość białka w konkretnych punktach geograficznych.




Rys. 2.5.3. Wycinek z analizy map plonów z systemu New Holland podczas zbiorów.

Wspomniany system wymaga określonej działalności wspomagającej, co było przewidziane w projekcie, ponieważ punkty pomiarowe są zbierane w różnych interwałach w zależności od ukształtowania terenu i trasy przejazdu, a w danych sporadycznie pojawiają się anomalie, które znacząco wpływają na wygląd całej mapy lub średnie dane statystyczne. Jest to pierwsze urządzenie tego typu na kombajnie zbożowym w Polsce, w związku z czym wszelkie działania wymagają szczególnej uważności w kontekście działania, awaryjności oraz pozyskiwania danych. Precyzyjne rozpoznanie tych anomalii na mapach oraz przygotowanie map do późniejszej analizy.


Wspólnie z rolnikami i analitykami QED udało się zidentyfikować następujące anomalie, które można było rozpoznać na bieżąco, analizując dane napływające do systemu podczas zbiorów:

- A. **Zawracanie kombajnu przy krawędzi działki** – chwilowa przerwa w podawaniu zboża, bez podnoszenia hedera na wysokość wstrzymującą pomiary.
- B. **Drugi przejazd po skoszonym terenie** – ze względu na wcześniej zebrane zboże w tym obszarze, pomiar jest znacznie zaburzony.
- C. **Zapchanie się młocarni** – mimo przejazdu i zbierania zboża, odczyty były zaniżone; należało zatrzymać ciągnik i wyczyścić elementy.
- D. **Zatrzymanie się kombajnu** w celu rozładowania zboża, wymiany elementów lub wyczyszczenia części.
- E. **Zebranie gleby w heder** – co wymusza zatrzymanie maszyny, zatrzymanie się przepływu masy zboża i wpływa na dokładność pomiaru.
- F. **Wyleganie uprawianej rośliny** – co może zakłócać odczyty.



Rys. 2.5.4. Przykład wyekstrahowanych danych z systemu ze wskazaniem anomalii typu A, B i C i ich wpływu na zmierzoną przez system masę plonu, kolor czerwony oznacza mocno zaniżony pomiar.

Dane wyekstrahowane z systemu New Holland wymagały identyfikacji oraz usunięcia anomalii dla wszystkich działek biorących udział w projekcie. Następnie, aby przygotować je do analiz plonu, konieczne było przeprowadzenie interpolacji, tak aby dane były ciągłe dla całego obszaru każdego pola.






SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO

Rys. 2.5.5. Prezentacja przygotowania danych na podstawie analiz anomalii podczas wykonywania precyzyjnego zabiegu zbiorów. Mapa po filtrowaniu i interpolacji nadaje się do dalszych analiz i jest najbardziej zbliżoną reprezentacją rzeczywistego zbioru.

Opracowane systemy służące filtracji i analizom danych plonowania zostaną wykorzystane do dalszych analiz dotyczących wpływu zawartości azotu w poszczególnych fazach rozwojowych na ostateczne parametry plonu, jak i również wykazania skuteczności stosowanych map nawożenia na wyrównanie jakości plonu.

2.6. Testowe modele suchej masy i mapy wilgotności uprawy

W ramach czterech kampanii pomiarowych opracowaliśmy wstępne modele determinacji suchej masy kukurydzy, umożliwiające ocenę jej przestrzennej zmienności na polu. Na podstawie map wilgotności plonu pokazujemy przykład, w którym zawartość suchej masy w obrębie jednego pola nie jest jednorodna, co wynika z różnych czynników, takich jak zmienność gleby, dostępność wody, topografia terenu czy mikroklimat. Różnice w strukturze gleby mogą wpływać na retencję wody i dostępność składników odżywczych, co prowadzi do nierównomiernego dojrzewania roślin. Ponadto warunki pogodowe, jak lokalne opady czy różnice w nasłonecznieniu, również mogą powodować zmienność wilgotności plonu na tym samym obszarze.



Rys. 2.6.1. Monitorowanie suchej masy za pomocą gęstej siatki punktów w obrębie jednego pola.

Największe różnice w obrębie jednego pola widoczne są podczas dojrzewania.

Możliwość szybkiego pomiaru suchej masy w wielu punktach uprawy jest kluczowa dla precyzyjnego określenia jej średniej wartości i podjęcia decyzji o optymalnym terminie zbioru na kiszonkę. W przypadku dużych różnic wilgotności, np. gdy połowa pola osiąga 25% suchej masy, a druga połowa 30%, teoretyczna średnia wynosi 27,5%, jednak nie gwarantuje to równomiernej jakości kiszonki. Kukurydza o znacznie zróżnicowanej wilgotności nie wymiesza się idealnie, co może prowadzić do problemów z fermentacją, nierównomiernym zakiszaniem oraz pogorszeniem stabilności kiszonki w czasie przechowywania. Dlatego precyzyjna wiedza o rozkładzie wilgotności w polu pozwala na odpowiednie zarządzanie zbiorami, a w niektórych przypadkach może wskazywać na konieczność oddzielnego zbioru bardziej wilgotnych i suchszych części pola.

Wnioski z przeprowadzonego badania pokazują przewagę metody szybkiego pomiaru w wielu punktach i tworzenia map nad tradycyjnym, punktowym poborem próbek roślinnych. Jeśli próby zostaną pobrane z miejsc niereprezentatywnych, rzeczywista zmienność wilgotności w obrębie pola może zostać błędnie oszacowana, co prowadzi do nietrafnych decyzji dotyczących zbioru i jakości kiszonki.



SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO

2.7. Podsumowanie

Opracowane w drugim etapie badania skupiły się na intensyfikacji poboru próbek i pogłębionej analizie parametrów roślin, co pozwoliło na lepsze zrozumienie rozkładu azotu w różnych organach pszenicy, rzepaku, jęczmienia i kukurydzy. Kluczowe było precyzyjne rozdzielanie próbek na liście, łodygi oraz części generatywne w zależności od fazy BBCH, co umożliwiło ocenę efektywności wykorzystania azotu w różnych etapach rozwoju roślin. Szczególny nacisk położono na pobór próbek kukurydzy w kluczowych fazach, co pozwoliło na stworzenie modelu wzrostu tej uprawy i określenie optymalnego terminu zbioru na kiszonkę. Dane laboratoryjne pochodzące z Okręgowych Stacji Chemiczno-Rolniczych wymagały ręcznej digitalizacji i statystycznej weryfikacji, co umożliwiło identyfikację oraz eliminację potencjalnych błędów pomiarowych.

Ważnym elementem prac było także opracowanie modeli predykcyjnych dla zawartości azotu w roślinach na podstawie danych spektralnych. Zastosowano różne metody przetwarzania danych, takie jak filtracja Savitzky'ego-Golaya, usunięcie linii bazowej czy pierwsza pochodna widm odbiciowych, co pozwoliło na poprawę jakości analizy. Wstępne modele uzyskały współczynnik determinacji $R^2 = 0,75$, co wskazuje na dobrą korelację między danymi spektralnymi a rzeczywistą zawartością azotu. Dodatkowo przeprowadzono analizy przestrzenne, które umożliwiły stworzenie testowych map nawożenia i wykazanie wyższej efektywności pomiarów optycznych w porównaniu do tradycyjnych analiz chemicznych. Na podstawie tych badań wyznaczono sektory o zróżnicowanej zawartości azotu, co stanowiło podstawę do dalszego dostosowywania dawek nawozowych. Pod koniec etapu rozpoczęto również analizę map plonów oraz wilgotności upraw, co pozwoli na lepsze planowanie zbiorów i poprawę jakości kiszonki gdy rozwiązanie trafi już na rynek.

3. Etap 3: Udoskonalenie modeli i analiza plonu (09.2023–11.2023)

3.1. Analiza parametrów plonu z punktów eksperymentalnych

Próbki plonu były pobierane w formie całych roślin z dwóch miejsc znajdujących się w pobliżu punktu zmiennego nawożenia na mapie. W każdej lokalizacji pobierano rośliny z dokładnie 1 m^2 , co pozwalało na uzyskanie dwóch niezależnych prób w obrębie tej samej strefy nawożenia. Takie podejście miało na celu zwiększenie reprezentatywności próbek oraz umożliwienie identyfikacji ewentualnych anomalii w danych.



SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO



Rys. 3.1.1. Prace polowe związane z pobieraniem próbek plonu do analizy.

Analiza plonu przeprowadzona została w oparciu o szereg parametrów agronomicznych i jakościowych, które mierzono zarówno w warunkach polowych, jak i laboratoryjnych. W pierwszym etapie na powierzchni 1 m^2 zliczano liczbę roślin oraz liczbę kłosów na m^2 , która równa była liczbie pędów na m^2 , co pozwoliło na ocenę zagęszczenia roślin. Następnie zbierano masę kłosów z wyznaczonej powierzchni, a po wymłóceniu określano plon z 1 m^2 jako masę ziaren z próby. Plon ten przeliczano na 15% wilgotności, aby umożliwić porównywalność wyników. Dla oceny jakości ziarna mierzono średnią masę ziarniaka oraz liczbę ziaren w kłosie, a także obliczano MTZ (masę tysiąca ziaren), co dostarczyło informacji o wielkości i jednorodności nasion. Dodatkowo, z próby pobierano masę słomy, a dla oceny morfologii roślin mierzono długość rośliny z kłosem oraz długość samego źdźbła na podstawie 20 losowo wybranych roślin.

W laboratorium, jakość ziarna analizowano za pomocą urządzenia Infratec firmy FOSS, które dostarczyło danych na temat zawartości białka (proteins), wilgotności, skrobi, mokrego glutenu, wskaźnika Zeleny'ego (jakość glutenu) oraz gęstość ziarna (test weight). Te parametry pozwoliły na kompleksową ocenę przydatności ziarna do celów konsumpcyjnych i przemysłowych. Wszystkie pomiary przeprowadzono zgodnie ze standardowymi protokołami, aby zapewnić dokładność i powtarzalność wyników, co umożliwiło rzetelną ocenę plonowania i jakości upraw.



SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO



Rys. 3.1.2. Pojedyncza próba badawcza przed i po wymłóceniu.



Rys. 3.1.3. Analiza jakościowa ziaren przy pomocy urządzenia foss infratec w laboratorium SGGW.



SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO


Lp.	Roślina	Punkt poboru gleby 2023	Punkt pomiarowy	Nawożenie	liczba roślin na 1m2	liczba kłosów na m2 = liczba pedów na 1m2	Plon z 1 m2 = masa ziaren z próby	Plon ziarna w przeliczeniu na 15%	liczba ziaren w kłosie	Średnia masa ziarna	MTZ	Masa słomy z próby	Masa kłosów	Długość rośliny z kłosem (20 szt)	Długość samego łodyga (20szt)
1	Jęczmień	36 B1/1	MIN		251	814	520		14,43988786	0,04424	44,24	529	592	62,9	47,6
2	Jęczmień	36 B1/2	MIN		218	913	600		15,25119868	0,04309	43,09	516	688	69	53,2
3	Jęczmień	35 B2/1	MED		256	890	676		19,36147239	0,03923	39,23	675	773	68,5	59,9
4	Jęczmień	35 B2/2	MED		314	1294	646		12,90326189	0,03869	38,69	613	735	71,7	56,2
5	Jęczmień	34 B3/1	MAX		190	870	496		13,95630214	0,04085	40,85	411	665	71	55,5
6	Jęczmień	34 B3/2	MAX		159	737	483		16,06667237	0,04079	40,79	501	572	74,6	58,1
7	Jęczmień	4 B4/1	MED		263	810	600		17,97914419	0,0412	41,2	478	685	73,8	57,2
8	Jęczmień	4 B4/2	MED		241	830	596		15,64427645	0,0459	45,9	423	677	71,2	54,3
9	Jęczmień	3 B5/1	MIN		225	629	385		14,35802653	0,04263	42,63	462	522	64,3	48
10	Jęczmień	3 B5/2	MIN		209	693	458		15,21396549	0,04344	43,44	324	532	75,8	47,6
11	Jęczmień	6 B6/1	MAX		224	1062	663		14,40124072	0,04335	43,35	692	768	72	56,6

Rys. 3.1.4. Wyciąg z bazy danych dotyczący ręcznej analizy plonu.


	A	B	C	D	E	F	G
1	Próbka	Proteins	Wilgotność	Skrobia	Gluten mokr	Zeleny	Test weight (gęstość ziarn)
2	W1/2	11.7	12.1	68.7	23.2	36.7	80.4
3	W6/2	10.6	12.2	69.2	20.9	29.9	79.2
4	W1/1	10.7	12.1	69.2	21.9	31.1	80.8
5	W8/2	9.8	12	70.8	20.6	27.3	82.6
6	W8/1	9.6	11.9	70.5	19.9	27	83.8
7	W6/1	10.1	12.2	69.7	19.9	28.5	79.5
8	W10/1	10.5	12	70	22.5	30.3	80.7
9	W10/2	9.5	12.1	70.5	19.3	23.1	78.1
10	W4/1	10.4	12.2	69.5	20	29	80.2
11	W11/2	11.6	11.9	68.6	24.1	36.4	77.5

Rys. 3.1.5. Wyciąg z bazy danych dotyczący analizy jakościowej plonu.

Analiza statystyczna plonu została przeprowadzona w celu oceny dystrybucji parametrów roślin i plonu, mając na uwadze uzyskanie szerokiego rozkładu wartości, co było kluczowe dla budowy modeli ML. W eksperymencie zastosowano trzy poziomy nawożenia: MIN, MED i MAX, a także uwzględniono różnorodne warunki glebowe, geograficzne i terenowe, aby zapewnić jak najszerszy zakres zmienności danych. Dodatkowo zbadano wpływ ograniczonego nawożenia na wyniki upraw, analizując potencjalne kompromisy między ilością i jakością plonu. Przykładowo, w przypadku pszenicy wyniki wskazują, że zwiększenie dawki nawożenia o 30% prowadzi jedynie do minimalnego wzrostu zawartości białka w ziarnach i wielkości plonu, co rodzi pytanie o ekonomiczną i agronomiczną zasadność takiego działania.




Rys. 3.1.6. Rozkład białka w próbkach plonu pszenicy.




Rys. 3.1.7. Rozkład wilgotności w próbkach plonu pszenicy

Przykładowe wykresy dla plonu pszenicy pokazują, że parametry jakościowe układają się zgodnie z rozkładem Gaussowskim, co wskazuje na stabilność danych i brak istotnych anomalii. Taki rozkład jest typowy dla tego rodzaju zmiennych i potwierdza przewidywalność ich statystycznej charakterystyki.







Rys. 3.1.8. Parametry jakościowe plonu pszenicy, skumulowane dla punktów o tym samym nawożeniu w celu pokazania proporcji między dawkami nawożenia.




Rys. 3.1.9. Parametry ilościowe plonu pszenicy, skumulowane dla punktów o tym samym nawożeniu w celu pokazania proporcji między dawkami nawożenia.




Rys. 3.1.10. Parametry jakościowe plonu jęczmienia, skumulowane dla punktów o tym samym nawożeniu w celu pokazania proporcji między dawkami nawożenia.





Rys. 3.1.11. Parametry ilościowe plonu jęczmienia, skumulowane dla punktów o tym samym nawożeniu w celu pokazania proporcji między dawkami nawożenia.




Rys. 3.1.12. Parametry jakościowe plonu rzepaku, skumulowane dla punktów o tym samym nawożeniu w celu pokazania proporcji między dawkami nawożenia.



Rzepak



Rzepak, Plon z 1m² masa nasion z próby



Rys. 3.1.13. Parametry ilościowe plonu rzepaku, skumulowane dla punktów o tym samym nawożeniu w celu pokazania proporcji między dawkami nawożenia.

Analiza wyników wykazała, że w niektórych przypadkach różnice w jakości plonu między poszczególnymi poziomami nawożenia mieszczą się w granicach błędu statystycznego. Sugeruje to, że niezależnie od zastosowanej dawki nawozu, rośliny były odpowiednio odżywione, co rodzi pytanie o zasadność stosowania standardowych dawek nawozowych. Ostateczna odpowiedź na to zagadnienie wymaga precyzyjnego pomiaru stanu azotu w roślinach bezpośrednio na polu, w wielu punktach. Takie podejście umożliwi dostosowanie dawki nawożenia do rzeczywistych potrzeb upraw, zamiast stosowania najwyższych dawek „na wszelki wypadek”. Przyniesie to zarówno korzyści ekonomiczne, redukując koszty nawożenia, jak i ekologiczne, minimalizując




SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO

nadmierne obciążenie środowiska. Ponadto, wykorzystanie precyzyjnych map nawożenia pozwoli na bardziej wyrównane parametry jakościowe plonu w obrębie całego pola, co może również ułatwić podejmowanie decyzji dotyczących optymalnego terminu zbiorów.

Wnioski wyciągnięte z analiz plonu oraz rozkładu parametrów roślin we wszystkich kampaniach pomiarowych pozwala na lepsze zaplanowanie eksperymentu w kolejnym sezonie. Obserwacja wpływu różnych dawek nawożenia ujawniła istotne zależności, które skłoniły nas do zastosowania bardziej radykalnego podejścia w dalszych badaniach. W nadchodzącym sezonie planujemy wprowadzenie dodatkowych wariantów z całkowitym brakiem nawożenia (dawki zerowe) na wybranych punktach badawczych, obok dotychczasowych dawek minimalnych. Pozwoli to dokładniej określić wpływ nawożenia na plon i jakość roślin, a także dostarczy cennych danych do optymalizacji strategii nawożenia w przyszłości.

Analizując praktyczne możliwości przewidywania parametrów plonu na podstawie spektrum, przetestowaliśmy cztery metody uczenia maszynowego: PLSR, RF, PCR i ET. Celem było znalezienie korelacji między widmem odbiciowym roślin a wybranymi cechami plonu. W przypadku pszenicy plon z 1 m² wykazywał najsilniejszą korelację z danymi spektralnymi zebranymi podczas drugiej kampanii pomiarowej (BBCH 39), co może wynikać z faktu, że w tym stadium rozwoju rośliny intensywnie akumulują biomasę i składniki odżywcze, co bezpośrednio wpływa na przyszły plon. Z kolei długość roślin była najlepiej skorelowana ze spektrum z trzeciej kampanii (BBCH 49), co może być związane z tym, że na tym etapie wzrost łodyg jest już bliski zakończenia, a finalna wysokość roślin jest bardziej ustabilizowana, umożliwiając dokładniejszą estymację na podstawie spektralnych właściwości rośliny. Analiza tych zależności dostarcza cennych informacji na temat optymalnych momentów pomiarowych dla różnych parametrów plonu, co pozwala na bardziej precyzyjne prognozowanie plonowania w przyszłych sezonach.



Rys. 3.1.14. Współczynniki korelacji przykładowych parametrów plonu ze spektrum odbiciowym w różnych kampaniach pomiarowych za pomocą różnych modeli uczenia maszynowego.




SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO

Wyniki z tego eksperymentu pokazały potencjał do przyszłych rozszerzonych badań, w których można bardziej szczegółowo przeanalizować wpływ faz rozwojowych roślin na skuteczność predykcji poszczególnych parametrów plonu. W szczególności interesujące byłoby sprawdzenie czy uwzględnienie dynamiki zmian spektralnych w kolejnych etapach wzrostu pozwoli na poprawę skuteczności modeli predykcyjnych oraz ich lepszą adaptację do różnych warunków środowiskowych i agrotechnicznych.

3.2. Analiza danych z urządzeń referencyjnych

W trakcie projektu, oprócz spektrometru ScanSpectrum, wykorzystywaliśmy również dostępne na rynku urządzenia, takie jak N-tester Yara oraz chlorofilomierz Apogee, które są powszechnie stosowane do pomiaru zawartości chlorofilu i azotu w roślinach. Urządzenia te, mimo swojej wysokiej ceny (10–15 tys. zł za sztukę), okazały się mieć znikomą korelację z rzeczywistą zawartością azotu oznaczoną w laboratorium OSCHR. W przeciwieństwie do nich, ScanSpectrum nie tylko lepiej przewiduje zawartość azotu w roślinach, ale także potrafi zasymulować wyniki jednostek CCI (Chlorophyll Content Index) czy N-testera, oferując przy tym znacznie szersze możliwości analityczne.



Rys. 3.2.1. Wyniki korelacji azotu roślinnego z urządzeniami referencyjnymi.

Wartość współczynnika determinacji R^2 dla korelacji CCI chlorofilomierza z laboratoryjnymi wynikami azotu roślinnego z OSCHR wynosi 0,0898, natomiast dla N-testera jest 0,2535. Na tej podstawie można stwierdzić, że N-tester wykazuje nieco lepszą zgodność z rzeczywistą zawartością azotu w roślinie niż CCI chlorofilomierz. Lepsza skuteczność N-testera może wynikać z tego, że mierzy on węższy zakres długości fal, które są bardziej bezpośrednio związane z azotem roślinnym, podczas gdy CCI chlorofilomierz bazuje na ogólnym poziomie chlorofilu, który nie zawsze jest idealnym wskaźnikiem zawartości azotu. Wpływ na wyniki może mieć także różna




SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO

kalibracja obu urządzeń oraz ich wrażliwość na czynniki środowiskowe, takie jak stres wodny czy etap wzrostu rośliny.

Jednak mimo nieco lepszego wyniku N-testera, oba urządzenia osiągają stosunkowo niską wartość R^2 , co sugeruje, że ich skuteczność w przewidywaniu rzeczywistej zawartości azotu w roślinach jest ograniczona. Wartość R^2 powinna być znacznie wyższa, aby można było uznać dane urządzenia za precyzyjne narzędzia do dokładnego monitorowania azotu.

Kluczowa różnica polega na metodzie pomiaru. ScanSpectrum mierzy ciągłe spektrum odbiciowe w zakresie od 400 do 1050 nm z rozdzielczością 0,5 nm, co daje 1300 efektywnych punktów pomiarowych. Dzięki temu urządzenie jest w stanie wychwycić subtelne zmiany w widmie odbiciowym roślin, które są silnie skorelowane z zawartością azotu. Tymczasem N-tester i chlorofilomierz opierają się na pomiarze tylko dwóch długości fal, co znacznie ogranicza ich dokładność i wiarygodność.



Rys. 3.2.2. Wykresy przedstawiające dokładność modeli predykcyjnych symulujących wyniki chlorofilomierza lub N-testera za pomocą urządzenia ScanSpectrum.

Co więcej, ScanSpectrum oferuje funkcjonalność obydwu urządzeń (pomiar chlorofilu i azotu) w jednym, a jego docelowa cena nie przekracza 3000 zł, co czyni go nie tylko bardziej ekonomicznym, ale także bardziej wszechstronnym i precyzyjnym narzędziem. Wynika to z faktu, że wykorzystuje on pełne spektrum światła, a nie tylko pojedyncze punkty pomiarowe, co pozwala na dokładniejsze odwzorowanie złożonych zależności między sygnałem spektralnym a zawartością azotu w roślinach.

Podsumowując, ScanSpectrum nie tylko przewyższa konkurencyjne urządzenia pod względem dokładności i wiarygodności wyników, ale także oferuje znacznie lepszy stosunek jakości do ceny, co czyni go idealnym rozwiązaniem dla nowoczesnego rolnictwa precyzyjnego.



SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO

3.3. Usprawnienia hardware, firmware i aplikacji mobilnej

Podsumowanie opinii od rolników i badaczy po pierwszym sezonie pomiarowym:

- Montaż powerbanka mógłby być łatwiejszy i szybszy
- Ze względu na konieczność wypełniania formularza dotyczącego uprawy, wygodniej byłoby mieć telefon zamocowany w pionie a nie w poziomie.
- Pomiar mógłby być znacznie szybszy, wykonywanie pomiarów spektralnych zajmowało większość czasu analizy zebranych próbek.
- Występowały problemy z kalibracją, wymagana była częsta ponowna kalibracja podczas kampanii pomiarowych, ze względu na pojawiające się szumy.
- W niektórych przypadkach byłoby łatwiej gdyby pomiar można było wykonywać jedną ręką.
- Zdarzały się problemy z połączeniem telefonu użytkownika z aplikacją mobilną.

Na podstawie doświadczeń rolników i badaczy zespół QED wykonał poprawki usprawniające ich pracę i przyszłe używanie urządzenia na polu. W Etapie 3 zakupione zostały części do produkcji pilotażowej 25 sztuk, części dobrano tak aby spełnić wymagania rolników dotyczące sprawności urządzenia. Największą zmianą był zakup najnowszego na rynku sensora pomiarowego kompatybilnego z modułami elektronicznymi spektrometru. Wybrany sensor charakteryzował się większą rozdzielczością i możliwym większym czasem naświetlania.

Dostosowanie układu optycznego spektrometru do nowego sensora i zmodyfikowanej soczewki było dużym wyzwaniem, należało wyrobić się z pracami badawczo rozwojowymi przed kolejnym sezonem pomiarowym, prace nad dostosowaniem, przetestowaniem i odpowiednią dokumentacją techniczną były wykonywane na etapie 3 i 4.


Problemy zaadresowane przez rolników i badaczy również należało rozwiązać przed rozpoczęciem kolejnych kampanii pomiarowych w drugim sezonie pomiarowym. Zgodnie z sugestiami badaczy, montaż powerbank został zastąpiony jednym szerokim rzepem zamiast dwoma wąskimi, co okazało się być praktycznym rozwiązaniem, znacznie ułatwiającym szybki montaż. Został wymieniony uchwyt i system montażu urządzenia mobilnego użytkownika, który pozwala na obrócenie go do orientacji pionowej. Wdrożenie nowego sensora, poprawek firmware i aplikacji mobilnej, pozwoliło na skrócenie procesu pomiarowego do 5 sekund na pomiar, podczas prac badawczych zespół rozpoczął eksplorację skrócenia czasu pomiaru do 2 sekund, przez dalsze modyfikacje układu optycznego oraz kodu aplikacji mobilnej.

Do nowej wersji urządzenia zastosowano również lepszą powłokę ochronną zapobiegającą zabrudzeniom obudowy urządzenia podczas prac terenowych.



Rys. 3.3.1. Po lewej wersja spektrometru przed usprawnieniami na podstawie opinii rolników, po prawej wersja usprawniona.

Wykonane zostały szerokie prace dotyczące dłuższego utrzymania poprawnej kalibracji spektrofotometru, w skład w których wchodziło automatyczne rozpoznawanie obszarów spektralnych sczytanych z sensora, rozpoznanie i redukcja dyfrakcji stożkowej po stronie software która również podwyższyła rozdzielczość pomiarową spektrometru oraz algorytmy korekcji obrazu które rozpoznają automatycznie zmiany w kalibracji wynikające ze wstrząsów lub gwałtownych zmian temperatury urządzenia.



Rys. 3.3.2. Testy rozwiązania dotyczącego redukcji dyfrakcji stożkowej oraz rozpoznawania obrazu i utrzymywania kalibracji.




SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO

3.4. Zakup części i produkcja serii pilotażowej na drugi sezon pomiarowy

W ramach etapu trzeciego przeprowadzono produkcję pilotażową urządzeń ScanSpectrum, które będą wykorzystywane w kolejnym sezonie pomiarowym. Na podstawie zebranych doświadczeń i opinii użytkowników zdecydowano się na wprowadzenie kluczowych usprawnień w konstrukcji sprzętu oraz oprogramowania, co pozwoliło na zwiększenie precyzji pomiarów, skrócenie czasu operacyjnego oraz poprawę ergonomii użytkowania urządzenia w terenie.

Zrealizowano zamówienia na komponenty elektroniczne, w tym nowy sensor spektralny o wyższej rozdzielczości, umożliwiający precyzyjniejsze pomiary spektralne w szerokim zakresie długości fal. Dostosowano układ optyczny, eliminując problemy związane z kalibracją oraz wpływem warunków środowiskowych na jakość pomiarów. Modernizacji poddano również system mocowania urządzenia oraz zasilanie – uproszczono montaż powerbanku, a także zastosowano bardziej efektywne zarządzanie energią, co zwiększyło czas pracy na jednym ładowaniu.

Przygotowanie serii pilotażowej objęło również opracowanie procedur montażowych oraz testów jakościowych, mających na celu wykrycie potencjalnych problemów produkcyjnych przed wdrożeniem urządzeń do szerokiego użytku. Szczególną uwagę poświęcono optymalizacji procesu kalibracji, aby zminimalizować konieczność jej częstego powtarzania podczas pracy w terenie. Produkcja pierwszej partii 25 urządzeń pozwoli na przeprowadzenie rozszerzonych badań w różnych warunkach uprawowych, weryfikację skuteczności nowego modelu pomiarowego oraz dalszą poprawę funkcjonalności systemu.





Rys. 3.4.1. Profesjonalne dedykowane moduły elektroniczne wykonane na potrzeby serii pilotażowej ScanSpectrum.



Rys. 3.4.2. Obudowy urządzenia ScanSpectrum wykonane metodą wtrysku na potrzeby serii pilotażowej.

Aby zapewnić powtarzalność wyników pomiarowych między urządzeniami oraz zweryfikować poprawność działania nowej serii spektrometrów, opracowano szczegółowy protokół testowy. Procedura obejmuje pomiary stosunku sygnału do szumu (SNR), które pozwalają określić jakość rejestrowanego sygnału w różnych warunkach oświetleniowych oraz stabilność działania układu optycznego i sensora. Dodatkowo przeprowadzane są testy na certyfikowanych wzorcach koloru

i szarości, umożliwiające kalibrację oraz ocenę precyzji odwzorowania wartości spektralnych w kluczowych zakresach długości fal. Pomiar szumu bazowego pozwala natomiast na identyfikację i minimalizację niepożądanych zakłóceń, które mogłyby wpływać na dokładność wyników. Każde urządzenie przed wdrożeniem do użytku przechodzi serię testów zgodnie z opracowanym protokołem, co zapewnia spójność i niezawodność pomiarów w różnych warunkach terenowych oraz zwiększa wiarygodność analiz przeprowadzanych na ich podstawie.

3.5. Rozpoczęcie budowy systemu do wytwarzania map nawożenia


Do testów systemu wytwarzania map nawożenia wykorzystane zostały wcześniej zebrane pomiary spektralne, wykonywane w wielu punktach na projektowych polach uprawnych. Do punktów zostały przypisane wartości azotu z wcześniej wytworzonych modeli predykcyjnych. Zaaplikowane do systemu - po odpowiedniej filtracji i interpolacji pozwoliły na wykonanie ciągłych map azotowych dla konkretnych działek. Aby zweryfikować nasze założenia, zestawiliśmy nasze predykcje azotu roślinnego z masą zebranego plonu.




Rys. 3.5.1. Mapa punktów pomiarowych pokolorowana po predykcji zawartości azotu z opracowanych modeli.




Poniżej znajdują się porównania mapy azotowych z mapami plonu które wskazują na korelację odpowiedniego odżywienia roślin z zebraną biomasa.




Rys. 3.5.2. Mapy przykładowych pól pszenicy - po lewej stronie predykcja azotu, po prawej plon.





Rys. 3.5.3. Mapy przykładowych pól jęczmienia - po lewej stronie predykcja azotu, po prawej plon.



Rys. 3.5.4. Mapy przykładowych pól rzepaku - po lewej stronie predykcja azotu, po prawej plon.

Przeprowadzone analizy nie tylko potwierdzają wpływ poziomu odżywienia roślin na uzyskiwany plon, ale również okazały się przydatne do ustalenia optymalnych odległości między punktami pomiarowymi, które zapewniają wystarczającą reprezentatywność pomiarów polowych. Wnioski wynikające z tych analiz zostaną uwzględnione w dalszym rozwoju systemu generowania map nawozowych.



SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO

Została również rozpoczęta implementacja systemu do obsługi map nawożenia. System opierać będzie się na interfejsie webowym w którym użytkownik będzie zarządzał swoimi uprawami i kampaniami pomiarowymi oraz aplikacji mobilnej zintegrowanej z systemem, dzięki której będą wykonane pomiary i wysyłane do chmury powiązanej z kontem użytkownika. Na etapie 3 został wykonany system rejestracji, logowania oraz łączenia aplikacji mobilnej “ScanSpectrum collect” dedykowanej do zbierania danych do map nawożenia z systemem webowym.

The screenshot displays two side-by-side web forms for the 'ScanSpectrum – Mapy nawozowe' application. The left form is titled 'Rejestracja' (Registration) and includes input fields for 'Nazwa użytkownika' (Username), 'Email', 'Hasło' (Password), and 'Powtórz hasło' (Repeat password), followed by a 'Zarejestruj się' (Register) button. The right form is titled 'Zaloguj się' (Login) and includes input fields for 'Nazwa użytkownika' and 'Hasło', followed by a 'Zaloguj się' button. Both forms have a link 'O projekcie' (About the project) and a link 'Nie masz konta? Zarejestruj się' (Don't have an account? Register) or 'Odzyskiwanie hasła' (Reset password).

Rys. 3.5.5. Ekrany rejestracji i logowania systemu webowego ScanSpectrum - Mapy nawozowe

The screenshot displays a web form for the 'ScanSpectrum – Mapy nawozowe' application. The form has a header with the application name and a link 'O projekcie'. Below the header, there is a section titled 'Zaloguj się do aplikacji' (Login to the application) with the text 'Zeskanuj poniższy kod QR w aplikacji ScanSpectrum Collect' (Scan the following QR code in the ScanSpectrum Collect application). Below this text is a large QR code.

Rys. 3.5.6. Ekran generowania kodu QR do zalogowania się z poziomu aplikacji mobilnej. Interfejs webowy jest zintegrowany z aplikacją mobilną.



SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO

Przedstawione rozwiązania, obejmujące interfejs webowy oraz aplikację mobilną, powstały w wyniku wielokrotnych konsultacji z rolnikami oraz ścisłej współpracy z wewnętrznym zespołem programistów QED. Dzięki temu udało się stworzyć optymalne narzędzie, które jest intuicyjne i wygodne w użytkowaniu na różnych etapach pracy w gospodarstwie. Analiza potrzeb użytkowników wykazała, że rolnicy preferują planowanie działań i zarządzanie nawożeniem z poziomu komputera osobistego, natomiast w terenie kluczowa jest łatwa i szybka dostępność aplikacji mobilnej. Aby uprościć proces logowania, zastosowano mechanizm jednorazowej autoryzacji przy zakładaniu konta, umożliwiając logowanie poprzez skanowanie kodu QR. Takie rozwiązanie zwiększa wygodę korzystania z systemu i minimalizuje czas potrzebny na operacje administracyjne, pozwalając użytkownikom skupić się na efektywnym zarządzaniu uprawami.

3.6. Podsumowanie

Podsumowując, etap trzeci projektu przyniósł istotne usprawnienia w analizie planowania oraz modelowaniu predykcyjnym. Wprowadzone algorytmy analizy przestrzennej w połączeniu z danymi z sensorów pozwoliły na szczegółową ocenę jakości i ilości plonu, uwzględniając różne poziomy nawożenia oraz warunki glebowe. Analiza statystyczna wykazała, że zwiększenie dawki nawożenia nie zawsze przekłada się na istotny wzrost jakości plonu, co otwiera nowe możliwości optymalizacji strategii nawożenia w przyszłości.

Dodatkowo, rozwój spektrometru ScanSpectrum oraz wdrożenie usprawnień w zakresie jego hardware'u i firmware'u pozwoliły na znaczne skrócenie czasu pomiarów i poprawę precyzji wyników. Prace nad systemem mapowania nawożenia umożliwiły integrację danych w nowoczesnym interfejsie webowym, co zwiększy funkcjonalność rozwiązania w kolejnym sezonie. Wyniki tego etapu stanowią solidną podstawę do dalszych badań i implementacji technologii rolnictwa precyzyjnego.




SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO

4. Etap 4: Zaawansowana analiza i przygotowanie do kolejnego sezonu pomiarowego (12.2023–03.2024)

4.1. Zaawansowana analiza danych

Przed przystąpieniem do zaawansowanej analizy modeli dane zostały poddane procesowi czyszczenia, aby odrzucić wszystkie niepoprawnie zebrane próby i uzyskać bardziej wiarygodne wyniki. W każdym punkcie pomiarowym wykonywano 15 skanów roślin, jednak mogły wystąpić przypadki, w których badacze niepoprawnie umieścili liść na oknie pomiarowym, co skutkowało uzyskaniem niereprezentatywnych danych. Niektóre skany mogły być zakłócone przez spektrum innych materiałów, takich jak palec operatora lub zanieczyszczone światłem zewnętrznym wpływającym na wynik. W celu identyfikacji i eliminacji odstających próbek przeprowadzono analizy statystyczne, w tym PCA (Principal Component Analysis), które pozwoliły na wykrycie nietypowych obserwacji w obrębie poszczególnych kampanii pomiarowych i gatunków roślin. Dzięki temu możliwe było zwiększenie jakości zbioru danych wykorzystywanego do budowy modeli predykcyjnych.




Rys 4.1.1. Analiza PCA w celu wykrycia odstających pomiarów w tym niepoprawnie wykonanych skanów.




SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO

Dla wszystkich gatunków modele uwzględniające wszystkie części roślin miały najniższy błąd predykcji (Symmetric Mean Absolute Percentage Error - SMAPE = 16% dla jęczmienia oraz 17% dla pszenicy i rzepaku). To samo dotyczyło modelu obejmującego wszystkie gatunki (19%). Jednak wszystkie modele, z wyjątkiem modeli opartych wyłącznie na organach generatywnych, miały $R^2 \geq 0,70$ i $SMAPE \leq 26\%$. Modele oparte wyłącznie na organach generatywnych dla pszenicy i rzepaku miały R^2 znacznie poniżej progu 0,70, na podstawie tego można wywnioskować że spektrum pomiarowe liści nie odzwierciedla zawartości azotu w częściach generatywnych, za to jest skorelowana z zawartością azotu w liściach, łodygach oraz w całej roślinie. Sugeruje to że opieranie się na pomiarach spektralnych w bardzo późnych fazach rozwoju gdy część generatywna ma istotny stosunek masy do masy całej rośliny, może być obarczone dużym błędem. W kontekście generowania map nawożenia ważne jest aby skupiać się na wczesnych fazach rozwoju, wtedy gdy można jeszcze modyfikować dawki planowanego nawożenia jednocześnie uzyskując najwyższą dokładność pomiaru spektralnego azotu.




Rysunek 4.1.2. Średnia zawartość azotu w całej roślinie: rzeczywista vs przewidywana przez PLSR w zbiorze danych obejmującym pszenicę, rzepak i jęczmień.



Rys. 4.1.3. Średnia zawartość azotu w całej roślinie: rzeczywista vs przewidywana przez PLSR, osobno dla każdej uprawy.



Modele oparte wyłącznie na liściach zapewniają rozsądne prognozy zawartości azotu.



Rys. 4.1.4. Zawartość azotu w liściach: rzeczywista vs przewidywana przez PLSR w pszenicy (górny lewy), rzepaku (górny prawy) i jęczmieniu (dolny lewy).

Jednym z najważniejszych zastosowań ScanSpectrum jest dostarczanie rolnikom rekomendacji dotyczących nawożenia na podstawie wczesnego etapu rozwoju roślin. W tym czasie dostępne do skanowania są jedynie liście. Z tego powodu modele oparte wyłącznie na liściach są dla nas szczególnie interesujące.

W przypadku wszystkich gatunków modele oparte tylko na liściach były w stanie wyjaśnić większość wariacji (R^2 dla pszenicy = 0,87, rzepaku = 0,78, jęczmienia = 0,79), co było zbliżone do wyników uzyskanych przez modele uwzględniające wszystkie części roślin. W przypadku pszenicy i jęczmienia błąd predykcji był również zbliżony do modelu uwzględniającego wszystkie części roślin (o 3 punkty procentowe wyższy w obu przypadkach). Natomiast w przypadku rzepaku błąd predykcji modelu opartego tylko na liściach wzrósł do 27% (w porównaniu do 18% w modelu uwzględniającym wszystkie części roślin we wszystkich kampaniach).



SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO

Możliwym wyjaśnieniem tego zjawiska jest duża różnica w zakresie wartości azotu pomiędzy pierwszą i drugą kampanią rzepaku. W pierwszej kampanii średnia zawartość azotu przekracza 5%, podczas gdy w drugiej kampanii spada poniżej 1%. Podobne zachowanie można zaobserwować w przypadku pszenicy, jednak w tym przypadku model ma również do dyspozycji trzecią kampanię, co może ułatwiać jego uogólnienie. Rzeczywiście, model pszenicy ograniczony do dwóch pierwszych kampanii wykazuje wyższy błąd predykcji (22%). W przypadku jęczmienia podobne zjawisko nie występuje.

Części rośliny	Kampanie	R ²	SMAPE
Liście	1-3	0.87	20%
Łodygi	2, 3, 5, 6	0.72	24%
Liście + łodygi	1, 2, 3, 5, 6	0.84	23%
Liście + części generatywne	1, 2, 3, 5, 6	0.67	22%
Wszystkie części	1, 2, 3, 5, 6	0.83	17%

Tabela 4.1.1. Pszenica

Części rośliny	Kampanie	R ²	SMAPE
Liście	1-2	0.78	27%
Łodygi	1-3	0.82	19%
Liście + łodygi	1-3	0.83	22%
Liście + części generatywne	1-3	0.85	20%
Wszystkie części	1-3	0.81	18%

Tabela 4.1.2. Rzepak



SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO

Części rośliny	Kampanie	R ²	SMAPE
Liście	1-2	0.79	18%
Łodygi	2, 4, 5	0.69	23%
Liście + łodygi	1, 2, 4, 5	0.82	20%
Liście + części generatywne	1, 2, 4, 5	0.69	17%
Wszystkie części	1, 2, 4, 5	0.78	15%

Tabela 4.1.3. Jęczmień

Części rośliny	Kampanie	R ²	SMAPE
Liście	1-3	0.84	26%
Łodygi	1-6	0.75	24%
Liście + łodygi	1-6	0.82	25%
Liście + części generatywne	1-6	0.65	23%
Wszystkie części	1-6	0.78	20%

Tabela 4.1.4. Wszystkie gatunki

Jako późne kampanie uznaliśmy trzecią kampanię rzepaku oraz wszystkie kolejne kampanie (pszenica: kampanie 4-6, jęczmień: kampanie 3-4). Modele przewidujące średnią zawartość azotu we wszystkich częściach roślin (tj. w łodygach i organach generatywnych na tych etapach) nie wykazały dobrej skuteczności.

Jednak modele uwzględniające wyłącznie łodygi dawały znacznie lepsze wyniki. W przypadku pszenicy i jęczmienia uzyskano $R^2 = 0,72$ oraz SMAPE wynoszące odpowiednio 23% i 21%. Model trenowany na danych obejmujących wszystkie gatunki osiągnął jeszcze lepsze wyniki – $R^2 = 0,83$ i SMAPE = 19%. Obydwa modele dla rzepaku wykazały słabą skuteczność, co jednak może wynikać z małej liczby próbek ($N = 12$), pochodzących z jednej kampanii.



SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO

Gatunek	Kampanie	R ²	SMAPE
Pszenica	5-6	0.72	23%
Rzepak	3	-0.09	13%
Jęczmień	4-5	0.72	21%
Wszystkie	3-6	0.83	19%


Tabela 4.1.5. Tylko łodygi

Gatunek	Kampanie	R ²	SMAPE
Pszenica	5-6	0.35	13%
Rzepak	3	0.07	8%
Jęczmień	4-5	0.65	11%
Wszystkie	3-6	0.64	11%

Tabela 4.1.6. Łodygi i części generatywne

W przypadku analizy kukurydzy w kontekście przewidywania zawartości suchej masy przeprowadzono szczegółowe analizy rozkładu wartości, które potwierdziły właściwy dobór warunków terenowych, terminów siewu, terminów poboru prób oraz innych czynników agrotechnicznych. Dzięki temu uzyskano odpowiedni rozrzut danych, co jest kluczowe dla zapewnienia ich wysokiej wartości jako zbioru treningowego dla modeli uczenia maszynowego. Równomierne pokrycie różnych wariantów uprawowych umożliwiło lepsze odwzorowanie rzeczywistych zależności w danych i zwiększyło potencjał predykcyjny modeli.

Dodatkowo przeprowadzono testy różnych modeli uczenia maszynowego, w tym m.in. PCR (Principal Component Regression) oraz ET (Extra Trees), w celu określenia ich skuteczności w prognozowaniu zawartości suchej masy/wilgotności kukurydzy. Modele oceniano pod kątem ich dokładności, odporności na przetrenowanie oraz zdolności do generalizacji na nowych danych. Wstępne wyniki wskazują, że zastosowanie technik opartych na redukcji wymiarowości oraz zespołowych metod drzewiastych może znacząco poprawić trafność przewidywań w porównaniu do tradycyjnych metod regresyjnych. Kolejne analizy pozwolą na optymalizację parametrów modeli oraz dalszą weryfikację ich skuteczności w różnych warunkach uprawowych.



Rys. 4.1.5. Prezentacja rozrzutu danych wilgotności rośliny względem kampanii pomiarowych oraz punktów poboru dla metody ET.



SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO

W analizie przewidywania suchej masy kukurydzy dodatkowo zbadano wpływ położenia liści na wyniki modeli predykcyjnych. Dla każdego punktu pomiarowego wykonywano 12 skanów liści górnych - pierwsze dwa górne liście, oraz 12 skanów liści dolnych - kolejne 2 liście. W tym celu analizowano cztery przypadki: „Razem 24 liście”, czyli średnią spektralną wszystkich liści pobranych z danej lokalizacji; „Górne liście” i „Dolne liście”, które odpowiadały średniej spektralnej osobno dla górnych i dolnych liści (po 12 próbek w każdej grupie); oraz „Razem 12 liści”, czyli średnią spektralną losowego zestawu 6 górnych i 6 dolnych liści. Ten ostatni przypadek dodano w celu sprawdzenia, czy lepsza skuteczność modeli predykcyjnych w analizie pełnego zestawu liści („Razem 24 liście”) wynika z większej ilości dostępnych informacji (co sugerowałoby, że rolnicy powinni skanować zarówno górne, jak i dolne liście), czy raczej z większej liczby próbek, a tym samym lepszego stosunku sygnału do szumu (SNR). W takim przypadku wystarczyłoby 12 próbek z górnych liści, zamiast równomiernego podziału na górne i dolne. Każda grupa zawierała od 84 próbek. W tabeli poniżej przedstawiono wyniki współczynnika R^2 .


Metoda uczenia maszynowego	Razem 24 liście	Razem 12 liści	Górne liście	Dolne liście
PLSR	0.55	0.63	0.54	0.49
ET	0.65	0.64	0.58	0.62
RF	0.67	0.56	0.57	0.56
PCR	0.69	0.68	0.58	0.63

Tabela 4.1.7. Wyniki współczynnika R^2

Ogólne wyniki przewidywania suchej masy kukurydzy okazały się akceptowalne, choć gorsze niż w przypadku modeli dla azotu. Zgodnie z analizą fizyczną, przewidywania wilgotności powinny ulec poprawie w poprawionej wersji ScanSpectrum która będzie wykorzystywana w kolejnym sezonie badawczym, dzięki wyższemu stosunkowi sygnału do szumu (SNR) w zakresie podczerwieni oraz właściwościom spektralnym wody w tym zakresie. Nie zaobserwowano znaczących różnic między skanami górnych i dolnych liści, jednak połączenie obu grup poprawiało wyniki we wszystkich przypadkach. Różnice były bardziej widoczne między zestawami „Razem 24 liście” a osobnymi „Górne liście” i „Dolne liście” niż między „Razem 12 liści” i „Razem 24 liście”. Co więcej, w niektórych modelach „Razem 12 liści” przewyższało „Razem 24 liście”, co sugeruje, że uwzględnienie zarówno górnych, jak i dolnych liści poprawia skuteczność predykcji, nawet jeśli całkowita liczba skanów pozostaje taka sama.




Spectral reflectance of maize leaves, range 420-1050 nm,
colored by dry mass (%)



Rys. 4.1.6. Spektre liści kukurydzy pokolorowane po zawartości suchej masy.

Weight measurement results and
model predictions for dry mass



Rys. 4.1.7. Prezentacja wyników modelu predykcji suchej masy kukurydzy za pomocą pomiaru spektralnego.



SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO

Wynik $R^2 = 0.72$ i $MAE = 3.2$ dla spektralnego modelu predykcyjnego suchej masy kukurydzy na kiszonkę wskazuje na skuteczność modelu i jego potencjał praktyczny. Model dobrze odwzorowuje rzeczywiste wartości, co jest obiecującym wynikiem, biorąc pod uwagę naturalną zmienność biologiczną roślin i wpływ czynników środowiskowych. $MAE = 3.2$ pokazuje, że średni błąd predykcji jest na poziomie bliskim do akceptowalnego, co wskazuje na potencjał przydatności w rolnictwie precyzyjnym do monitorowania dojrzałości roślin.

Jednak nadal istnieją obszary do usprawnienia, które będą realizowane w kolejnym sezonie. Zebranie większej liczby próbek zwiększy różnorodność danych treningowych i pozwoli lepiej uchwycić zmienność w zawartości suchej masy. Dodatkowo zastosowany zostanie usprawniony spektrometr ScanSpectrum z szerszym zakresem pomiarowym i lepszym stosunkiem sygnału do szumu (SNR) w zakresie podczerwieni, która jest bardzo ważna w przypadku pomiarów związanych z zawartością wody, co powinno poprawić dokładność modeli predykcyjnych. Dzięki tym ulepszeniom możliwe będzie dalsze zwiększenie skuteczności metody i uzyskanie jeszcze bardziej precyzyjnych wyników.


Członkowie Koła Naukowego Rolników, zaangażowani w działania konsorcjum, wzięli udział w Przeglądzie Kół Naukowych SGGW, gdzie zdobyli drugie miejsce w konkursie na najlepszy projekt badawczy. Ich prezentacja skupiła się na możliwościach wykorzystania pomiarów spektralnych do oceny zawartości azotu roślinnego za pomocą urządzenia ScanSpectrum. Podczas konkursu przedstawili wyniki analiz oraz potencjał technologii w rolnictwie precyzyjnym, zwracając uwagę na dokładność uzyskiwanych pomiarów w porównaniu do tradycyjnych metod oceny składu roślin.



Rys. 4.1.8. Plakat Koła Naukowego Rolników o zastosowaniu ScanSpectrum do analizy azotu roślinnego.

4.2. Usprawnienie urządzeń pomiarowych

Zespół QED kontynuował prace nad usprawnieniem spektrometru, obejmujące zarówno oprogramowanie, firmware, hardware, jak i proces kontroli jakości podczas składania urządzenia. Po stronie software wdrożono algorytm wykrywania krzywizny obrazu i jego automatyczne prostowanie, co znacząco poprawiło stabilność kalibracji. Dzięki temu zminimalizowano wpływ niewielkich odchyłek podczas montażu elementów optycznych na dokładność pomiarów, co przełożyło się na bardziej powtarzalne i precyzyjne wyniki.




Rys. 4.2.1. Testy algorytmu do wykrywania i prostowania obszarów spektralnych w celu poprawienia rozdzielczości pomiarowej i zapobiegania dekalibracji.

W zakresie hardware dokonano istotnych zmian w układzie optycznym, zwiększając ilość światła docierającego do sensora przy zachowaniu wysokiej rozdzielczości pomiarowej. Moc źródła światła została zwiększona o 50%, a dotychczasowa szczelina polimerowa została zastąpiona szczeliną powietrzną wykonaną ze stali nierdzewnej, co dodatkowo podniosło intensywność światła o 20%. Te modyfikacje wymagały również dostosowania metody kalibracji po stronie software, aby zapewnić optymalną kompensację zmian w natężeniu sygnału. Dzięki zwiększeniu ilości światła docierającego do sensora udało się znacząco skrócić czas pojedynczego pomiaru, jednocześnie utrzymując wysoki stosunek sygnału do szumu (SNR), co wpłynęło na jeszcze większą precyzję i efektywność działania spektrometru.




SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO



Rys. 4.2.2. Szczeliny powietrzne wykonane precyzyjnymi laserami w arkuszu stali nierdzewnej.

Po stronie procesu montażu wprowadzono specjalistyczne programy komputerowe usprawniające wstępną kalibrację drogi optycznej. Dzięki zastosowaniu algorytmów rozpoznawania obrazu, stanowiska montażowe automatycznie wykrywają krzywiznę i precyzję pozycjonowania elementów optycznych, co pozwala na ich korektę jeszcze przed finalnym złożeniem spektrometru. Takie podejście znacząco zwiększyło powtarzalność parametrów urządzeń oraz poprawiło jakość pomiarów, eliminując potencjalne błędy wynikające z mikroskopijnych odchyłek w montażu.



Rys. 4.2.3. Program do rozpoznawania krzywizny obrazu na stanowisku montażowym.

Jedną z uwag zgłaszanych przez rolników i badaczy był brak możliwości wykonywania pomiarów jedną ręką, co utrudniało pracę w terenie, gdy przemieszczali się też z innym sprzętem pomiarowym lub sprzętem do poboru prób. W odpowiedzi na tę potrzebę zespół QED opracował rozszerzenie zestawu w postaci przestony dociskowej wyzwalanej dźwigni. Rozwiązanie to pozwalało na stabilne umieszczenie próbki i wykonanie pomiaru bez konieczności użycia drugiej ręki. Co istotne, wdrożenie tej modyfikacji nie wymagało zmian w konstrukcji spektrometru – opracowany mechanizm był montowany na głowicy urządzenia jako dodatkowy moduł, co umożliwiało jego łatwe zastosowanie w istniejących egzemplarzach.




Rys. 4.2.4. Rozszerzenie zestawu pomiarowego o możliwość wykonywania pomiarów liści jedną ręką.



SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO

Spektrometr ScanSpectrum został zwalidowany za pomocą standardów Spectralon certyfikowanych przez NIST (Narodowy Instytut Standaryzacji i Technologii w USA). Wykorzystanie tych wzorców, w połączeniu z pomiarami przeprowadzonymi na wysokiej klasy laboratoryjnym spektrometrze odbiciowym, pozwoliło na dokładne sprawdzenie poprawności uzyskiwanych wyników. Spektra zmierzone za pomocą ScanSpectrum wykazały praktycznie idealną zgodność z widmami standardów uzyskanymi z urządzenia kosztującego ponad 50 razy więcej niż docelowa cena ScanSpectrum. Wynik ten potwierdza wysoką jakość i precyzję pomiarów, a także pokazuje, że technologia ScanSpectrum może stanowić niskokosztową alternatywę dla drogich spektrometrów laboratoryjnych, umożliwiając analizy w terenie.



Rys. 4.2.5. Standardy Spectralon wraz z ich spektrami zmierzonymi za pomocą ScanSpectrum i drogiego spektrometru laboratoryjnego Shimadzu UV3600i Plus.

Na kolejny sezon pomiarowy mamy gotowy zestaw urządzeń, które wykonują pomiary w zaledwie 2 sekundy, osiągając stosunek sygnału do szumu (SNR) 500. Dodatkowo, zakres pomiarowy został rozszerzony z 400-1050 nm do 400-1150 nm, co było możliwe dzięki wymianie sensora na nowszy model, opisaną w poprzednich etapach. Jest to znaczące usprawnienie w porównaniu do poprzedniej wersji spektrometru, gdzie czas pomiaru wynosił około 8 sekund, a SNR sięgał jedynie 200. Dzięki tym zmianom możliwe będzie zbieranie większej ilości dokładniejszych danych, co przełoży się na budowę lepszych modeli predykcyjnych.

W kolejnym sezonie badacze będą przeprowadzać pomiary za pomocą dwóch wersji spektrometru, co pozwoli na zebranie danych zarówno z nowej, jak i starszej wersji urządzenia. Celem jest sprawdzenie, czy większy wpływ na skuteczność modeli ma większa liczba próbek, czy też wyższa jakość pojedynczych pomiarów. Dodatkowo przeanalizowane zostaną możliwości łączenia zestawów danych z obu wersji spektrometru po odpowiednim przetworzeniu, co może otworzyć nowe perspektywy dla poprawy dokładności przewidywań.




4.3. Przygotowanie do badań polowych

Założeniem w kolejnym sezonie pomiarowym jest uzyskanie jeszcze większego zróżnicowania zawartości azotu roślinnego, niż udało się to osiągnąć w pierwszym sezonie. W tym celu punkty polowe zostały dobrane w sposób analogiczny do poprzedniego sezonu, jednak z uwzględnieniem dodatkowych czynników. Selekcja lokalizacji opierała się na analizie obrazów wegetacyjnych z satelitów, mapie typów i granulometrii glebowej oraz płodozmianie, a także wynikach badań glebowych określających zawartość azotu w glebie.



Rys. 4.3.1. Przykład wyboru punktów pomiarowych na podstawie satelitarnych map wegetacyjnych w celu osiągnięcia różnorodności danych.



Rys. 4.3.2. Mapa zasobności azotu glebowego na działkach ewidencyjnych biorących udział w projekcie.



Tabela wyników

Kod laboratoryjny próbki	Informacje od Klienta			Zawartość w mg/kg s.m. gleby		Zawartość N _{min} w kg/ha ²⁾	Zawartość N _{min} w kg/ha w warstwie 0-60 ²⁾	zasobność ¹⁾
	Warstwa cm	Oznaczenie próbki	Kategoria agronomiczna gleby	N-NO ₃	N-NH ₄			
GX/16/1	0-30	1	średnia	7,35	4,82	52,30	137,30	bardzo wysoka
GX/16/2	31-60	1		18,02	1,74	85,00		
GX/16/3	0-30	2	średnia	7,62	1,62	39,70	64,80	niska
GX/16/4	31-60	2		3,15	2,68	25,10		
GX/16/5	0-30	3	średnia	6,79	3,20	43,00	77,80	średnia
GX/16/6	31-60	3		4,41	3,69	34,80		
GX/16/7	0-30	4	średnia	6,68	3,83	45,20	83,20	średnia
GX/16/8	31-60	4		3,94	4,89	38,00		
GX/16/9	0-30	5	średnia	7,97	2,61	45,50	74,10	średnia
GX/16/10	31-60	5		4,01	2,64	28,60		
GX/16/11	0-30	6	średnia	7,48	2,25	41,80	80,80	średnia
GX/16/12	31-60	6		7,10	1,96	39,00		

Rys. 4.3.3. Wyciąg z tabeli wyników badań gleby na zawartość azotu.


Aby osiągnąć maksymalny zakres zawartości azotu roślinnego, zespół postanowił wykorzystać wszystkie kombinacje poziomu azotu w glebie oraz poziomu nawożenia, uwzględniając również wariant zerowy. W planie badawczym uwzględniono punkty zero, min, med i max dla niskiej, średniej i wysokiej zasobności glebowej, co pozwoliło na pełne pokrycie możliwych scenariuszy odżywienia roślin azotem. Takie podejście zapewnia maksymalną różnorodność danych i pozwala na precyzyjniejsze określenie relacji między zawartością azotu a sygnałem spektralnym. Opisane kombinacje zostały zastosowane dla każdego rodzaju uprawy biorącej udział w projekcie.

Gospodars two	Roślina	Punkt	Dawka	Nawożenie kontrolne 1 dawka (kg/ha)	Nawożenie 1 dawka surowiec	nawożenie 1 dawka kilogramy	nawożenie 1 dawka czysty azot	Data 1 nawożenia	Nawożenie kontrolne 2 dawka (kg/ha)	Nawożenie 2 dawka surowiec	nawożenie 2 dawka kilogramy	nav 2 czy
Czech	Pszenica	1	MED	210	Zaksan 33,5	250	83,75	08.03.2024	100	ZAKSAN 33,5	20	
Czech	Pszenica	2	Zero	210	Zaksan 33,5	10	3,35	08.03.2024	100	ZAKSAN 33,6	10	
Czech	Pszenica	3	max	210	Zaksan 33,5	320	107,2	08.03.2024	100	ZAKSAN 33,7	150	
Czech	Pszenica	4	min	210	Zaksan 33,5	150	50,25	08.03.2024	100	ZAKSAN 33,8	10	
Czech	Pszenica	5	zero	210	Zaksan 33,5	10	3,35	08.03.2024	100	ZAKSAN 33,9	10	
Czech	Pszenica	6	zero	210	Zaksan 33,5	10	3,35	08.03.2024	100	ZAKSAN 33,10	10	
Czech	Pszenica	7	max	210	Zaksan 33,5	320	107,2	08.03.2024	100	ZAKSAN 33,11	150	
Czech	Pszenica	8	med	210	Zaksan 33,5	250	83,75	08.03.2024	100	ZAKSAN 33,12	20	
Czech	Pszenica	9	min	210	Zaksan 33,5	150	50,25	08.03.2024	100	ZAKSAN 33,13	0	
Czech	Pszenica	10	min	210	Zaksan 33,5	150	50,25	08.03.2024	100	ZAKSAN 33,14	0	
Czech	Pszenica	11	med	210	Zaksan 33,5	250	83,75	08.03.2024	100	ZAKSAN 33,15	20	
Czech	Pszenica	12	zero	210	Zaksan 33,5	10	3,35	08.03.2024	100	ZAKSAN 33,16	0	
Czech	Pszenica	13	min	210	Zaksan 33,5	150	50,25	08.03.2024	100	ZAKSAN 33,17	0	

Rys. 4.3.4. Wycinek planu nawożenia na sezon 2024



SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO



Rys. 4.3.5. Fragment mapy na sezon 2024 z zaznaczonymi działkami i punktami na których będą odbywać się pomiary

W sezonie 2024, na podstawie obserwacji z poprzedniego sezonu, postanowiliśmy zagęścić pomiary we wcześniejszych fazach rozwojowych, aby lepiej uchwycić dynamiczne zmiany w zawartości azotu oraz cechach morfologicznych roślin. Wczesne etapy wzrostu są kluczowe dla efektywnego zarządzania nawożeniem, ponieważ to właśnie wtedy rośliny intensywnie pobierają składniki odżywcze, co znajduje bezpośrednie odzwierciedlenie w ich spektralnym sygnale odbiciowym.

Dodatkowo zwiększono liczbę punktów pomiarowych, aby zapewnić większą różnorodność warunków glebowych i uprawowych. W nowym sezonie wyznaczono po 17 punktów pomiarowych dla pszenicy, rzepaku i jęczmienia oraz 21 dla kukurydzy, co pozwoli na uzyskanie bardziej reprezentatywnej próby i dokładniejsze odwzorowanie zmienności plonu w różnych lokalizacjach. Większa liczba punktów zwiększy także precyzję modeli predykcyjnych, umożliwiając lepsze określenie zależności między widmem odbiciowym a parametrami fizjologicznymi roślin.

Dzięki tym zmianom uzyskane dane powinny nie tylko poprawić skuteczność predykcji, ale również dostarczyć cennych informacji dla rolnictwa precyzyjnego, pozwalając na jeszcze bardziej efektywne dostosowanie strategii nawożenia do rzeczywistych potrzeb roślin w różnych warunkach środowiskowych.




SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO

4.4. Środowisko do generowania map nawozowych

Na każdym etapie prac priorytetem było zapewnienie, aby tworzony system odpowiadał realnym potrzebom użytkowników końcowych. W tym celu przeprowadzono szeroko zakrojone konsultacje z rolnikami z różnych regionów, reprezentujących zróżnicowane profile gospodarstw. Ich wiedza i doświadczenie były kluczowe przy definiowaniu oczekiwań wobec funkcjonalności systemu, sposobu prezentacji wyników oraz integracji z istniejącymi praktykami agrotechnicznymi.


Równolegle prowadzono intensywne testy A/B mające na celu optymalizację interfejsu użytkownika oraz działania całego procesu, od rejestracji, inicjalizacji pól po wykonywanie pomiarów i generowanie map nawożenia pod wymagane standardy. Przetestowano wiele wariantów graficznych oraz schematów działania aplikacji, koncentrując się na takich aspektach jak: szybkość dostępu do danych, czytelność map nawozowych, możliwość łatwej edycji zaleceń oraz integracja z maszynami rolniczymi (m.in. przez formaty plików zgodne z systemami precyzyjnego rolnictwa). Poniżej przedstawione zostały przykładowe materiały wykorzystane do konsultacji.



Rys. 4.4.1. Ekran testowy środowiska w interfejsie webowym - widok pól.



SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO




Rys. 4.4.2. Ekran testowy środowiska w interfejsie webowym - dodawanie pola.

Moje kampanie						
Nazwa	Status	Pole	Uprawa	Data rozpoczęcia	Data zakończenia	
Kampania 1	W trakcie	Pole 1	kukurydza	24.06.2024	-	Zakończ
Kampania 2	Zakończona	Pole 2	kukurydza	24.08.2023	24.09.2023	Eksportuj wyniki
Kampania 3	Zakończona	Pole 2	kukurydza	24.08.2023	24.09.2023	Podgląd
Kampania 3	Zakończona	Pole 2	kukurydza	24.08.2023	24.09.2023	Podgląd
Kampania 3	Zakończona	Pole 2	kukurydza	24.08.2023	24.09.2023	Podgląd
Kampania 3	Zakończona	Pole 2	kukurydza	24.08.2023	24.09.2023	Podgląd
Kampania 3	Zakończona	Pole 2	kukurydza	24.08.2023	24.09.2023	Podgląd
Kampania 3	Zakończona	Pole 2	kukurydza	24.08.2023	24.09.2023	Podgląd

Rys. 4.4.3. Ekran testowy środowiska w interfejsie webowym - kampanie pomiarowe.



SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO




Rys. 4.4.4. Ekran środowiska systemu w interfejsie webowym - kampanie pomiarowe.


Wyniki testów i konsultacji pozwoliły na wypracowanie ostatecznych założeń rozwiązania, które łączy zaawansowaną analizę danych z prostotą obsługi. Zbudowane środowisko wspiera użytkownika na każdym etapie – od zbierania danych spektralnych w polu, przez przetwarzanie i analizę, aż po generowanie zaleceń nawozowych dostosowanych do zmienności przestrzennej upraw.

Dzięki bezpośrednim konsultacjom programistów z rolnikami powstał szczegółowy opis działania systemu do zbierania danych w terenie oraz tworzenia map nawożenia azotowego. W trakcie wspólnych prac ustalono wpływ poszczególnych danych pomocniczych – takich jak faza rozwojowa roślin, gęstość obsady czy występowanie stresu roślin – na końcowy kształt map nawożenia. Dodatkowo omówiono i doprecyzowano działanie algorytmów przetwarzania danych, aby zapewnić ich zgodność z praktycznymi wymaganiami użytkowników w gospodarstwach rolnych.

Schemat pomocniczy poniżej, przedstawia przepływ danych i kolejność wykonywanych działań – od zbierania informacji w polu, przez ich przesyłanie i analizę, aż po wygenerowanie map nawożenia gotowych do zastosowania w rozsiewaczach.



Rys. 4.4.5. Schemat części ustaleń workflow po stronie rolnika.



Rys. 4.4.6. Schemat dotyczący ustaleń przepływu danych w całym systemie.



SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO

4.5. Podsumowanie

Czwarty etap projektu skupił się na oczyszczeniu i pogłębionej analizie danych spektralnych, a także na przygotowaniach do kolejnego sezonu pomiarowego. Szczególny nacisk położono na eliminację błędnych skanów, co pozwoliło na znaczną poprawę jakości zbioru danych używanego do trenowania modeli predykcyjnych. Dokładne sprawdzenie skuteczności modeli dla różnych części roślin ujawniło, że pomiary liści w początkowych fazach rozwoju mają największy potencjał prognostyczny. Modele oparte na liściach, istotnych z punktu widzenia wczesnych decyzji nawozowych, osiągnęły najwyższe wyniki korelacji z wynikami laboratoryjnymi, co dowodzi ich praktycznej przydatności. Zaobserwowano jednak, że w późniejszych fazach wzrostu skuteczność predykcji spada, zwłaszcza gdy istotną częścią biomasy są części generatywne.

Równolegle trwały prace nad dalszym rozwojem samego urządzenia ScanSpectrum, które objęły zarówno modernizację hardware'u, jak i usprawnienia software'u. Zmniejszenie czasu pomiaru do 2 sekund oraz rozszerzenie zakresu pomiarowego do 1150 nm oraz poprawienie stosunku sygnału do szumu, przełoży się na dane wyższej jakości w nowym sezonie. Oprócz poprawy jakości sprzętu, krokami przygotowawczymi do kolejnego sezonu było również ustalenie nowych punktów i nawożenia na podstawie analiz wszystkich dostępnych danych i wniosków z ostatniego sezonu. Zastosowane będzie jeszcze większe zróżnicowanie warunków glebowych i nawożenia.



SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO

5. Etap 5: Kolejny sezon badawczy, przygotowanie finalnych rozwiązań do wdrożenia (04.2024–04.2025)

5.1. Pobór i pomiary próbek roślinnych - sezon 2024

W nowym sezonie pomiarowym skupiliśmy się na początkowych fazach rozwojowych, aby lepiej uchwycić dynamikę pobierania azotu i innych składników odżywczych przez rośliny. Wczesne etapy wzrostu są kluczowe dla określenia kondycji upraw i optymalizacji nawożenia, dlatego harmonogram pobierania próbek został dostosowany tak, aby obejmować kluczowe momenty rozwoju roślin.

Pszenica była zbierana w fazach BBCH 13 (trzy liście rozwinięte), BBCH 27 (pełnia krzewienia), BBCH 31 (pierwsze kolanko), BBCH 49 (liść flagowy rozwinięty) oraz BBCH 75 (dojrzałość mleczna, przed zbiorami).

Rzepak analizowano w fazach BBCH 15 (pięć liści rozwiniętych), BBCH 19 (koniec fazy liściowej), BBCH 43 (wydłużanie pędu głównego), BBCH 51 (początek pąkowania), BBCH 62 (początek kwitnienia).

Jęczmień pobierano w fazach BBCH 19 (koniec fazy krzewienia), BBCH 31 (pierwsze kolanko), BBCH 49 (liść flagowy rozwinięty), BBCH 75 (dojrzałość mleczna, przed zbiorami).

Dzięki takiemu rozplanowaniu próbek możliwe było dokładniejsze odwzorowanie zmian fizjologicznych roślin oraz ich reakcji na różne poziomy nawożenia. Porównanie danych z wczesnych i późniejszych faz wzrostu pozwoli na ocenę długoterminowego wpływu warunków uprawowych oraz dostarczy jeszcze bardziej precyzyjnych informacji do budowy modeli predykcyjnych.



SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO



Rys. 5.1.1. Zestawy ScanSpectrum przygotowane do wykonywania pomiarów.



Rys. 5.1.2. Rzepak ozimy podczas wczesnych prac polowych 2024.



SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO



Rys. 5.1.3. Badacz podczas pobierania próbek materiału roślinnego w sezonie 2024.



SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO



Rys. 5.1.4. Pobór próbek rzepaku w fazie kwitnienia, sezon 2024.

Pomiary spektralne w tym sezonie, wykonywane zarówno za pomocą starszej, jak i nowej wersji urządzenia, zajmowały więcej czasu niż w poprzednim roku, jednak dzięki odpowiedniej logistyce i organizacji pracy proces przebiegał sprawnie. Kluczowe było rozdystrybuowanie odpowiedniej liczby urządzeń na każde gospodarstwo, co pozwoliło na równoległe prowadzenie pomiarów w wielu lokalizacjach jednocześnie. Dodatkowo zwiększone zaangażowanie badaczy umożliwiło efektywną realizację harmonogramu, a ścisła koordynacja zespołów terenowych zapewniła płynność całego procesu. Próbkę były przygotowywane do wysyłki tego samego dnia, w którym dokonano poboru i pomiaru, co pozwoliło na szybkie przetwarzanie danych oraz minimalizację wpływu czynników zewnętrznych na ich jakość.



Rys. 5.1.5. Zespół badawczy podczas pomiarów i pakowania próbek materiału roślinnego do laboratorium chemicznego, sezon 2024

Próbki kukurydzy były pobierane w czterech kluczowych fazach rozwojowych, zachowując podział na liście górne i dolne oraz wykonując pomiary za pomocą dwóch wersji spektrometru. Dzięki temu możliwe było dokładne prześledzenie zmian spektralnych w różnych etapach dojrzewania roślin i ich wpływu na modele predykcyjne.

Pobory próbek przeprowadzono w następujących fazach BBCH:

- BBCH 71 – początek wypełniania ziarna, faza mleczna, liście w pełni rozwinięte.
- BBCH 75 – faza mleczna, ziarna miękkie, intensywny wzrost biomasy.
- BBCH 83 – początek fazy woskowej, ziarna zaczynają twardnieć.
- BBCH 87 – późna faza woskowa, zbliżająca się dojrzałość fizjologiczna.

Takie podejście pozwoliło uchwycić kluczowe momenty zmian w strukturze rośliny oraz jej składzie chemicznym, co umożliwi dalszą optymalizację analizy spektralnej i budowy modeli predykcyjnych dla parametrów kukurydzy na kiszonce.



Rys. 5.1.6. Wizualnie widoczne różnice w wilgotności kukurydzy w tym samym terminie pomiarowym na dwóch różnych polach.

OSCHR 2024 data cumulated

File Edit View Insert Format Data Tools Extensions Help

100% 123 Default... 10 + B I A

M2

Summarize this table

	A	B	C	D	E	F	G	H	I	J	K	L	M
1	Lp.	Oznaczenie próbki	N (% p.s.m)	P (% p.s.m)	K (% p.s.m)	Sucha masa w %	%s.m. z p.s.m	N (% s.m)	P (% s.m)	K (% s.m)	Chlorophyll (CCI N-tester	Masa po zdebra M	
143	24	1407 pszenica cała roślina	1.90	0.33	1.90	30.7	89.99	2.20	0.31	2.20	40.3	723	3.34
144	25	1408 pszenica cała roślina	1.38	0.27	1.53	36.8	90.39	1.53	0.30	1.69	26.8	636	1.98
145	26	1409 pszenica cała roślina	1.43	0.33	2.52	26.6	89.55	1.60	0.37	2.81	37	688	3.87
146	27	1410 pszenica cała roślina	1.29	0.26	1.48	36.7	90.33	1.43	0.29	1.64	27.1	603	3.41
147	28	1411 pszenica cała roślina	1.76	0.28	2.1	27.1	90.03	1.95	0.31	2.33	34.1	650	9.55
148	29	1412 pszenica cała roślina	1.28	0.25	1.48	36.9	89.79	1.43	0.28	1.65	27.5	630	2.86
149	30	1413 pszenica cała roślina	1.47	0.21	1.65	32.1	90.25	1.63	0.23	1.83	25.9	609	3.60
150	31	1414 pszenica cała roślina	1.39	0.21	1.72	34.3	89.81	1.55	0.23	1.92	23.7	624	5.23
151	32	1415 pszenica cała roślina	1.59	0.24	2.15	28	90.02	1.77	0.27	2.39	51	645	4.57
152	33	1416 pszenica cała roślina	2.02	0.29	2.62	31.3	89.46	2.26	0.32	2.93	27.9	634	5.31
153	34	1417 pszenica cała roślina	1.5	0.23	1.82	36.7	89.78	1.67	0.26	2.03	24.3	567	1.82
154	35	3101 jęczmień cała roślina	2.97	0.25	3.05	19.9	87.85	3.38	0.28	3.47	19.8	645	6.79
155	36	3102 jęczmień cała roślina	3.12	0.38	3.75	28.2	87.59	3.56	0.43	4.28	14.7	584	1.31
156	37	3103 jęczmień cała roślina	3.29	0.35	3.81	26.6	87.92	3.74	0.40	4.33	17.9	536	0.98
157	38	3104 jęczmień cała roślina	3.44	0.4	3.86	16.7	88.36	3.89	0.45	4.37	20.3	598	4.20
158	39	3105 jęczmień cała roślina	3.25	0.30	3.50	24	87.77	3.70	0.44	4.06	33.2	610	2.45

Rys. 5.1.7. Wyciąg z bazy danych roślinnych - sezon 2024.



SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO

5.2. Przygotowanie dokumentacji technicznej

W ramach przygotowań do certyfikacji CE i wdrożenia produktu na rynek opracowano kompleksową dokumentację techniczną, obejmującą wszystkie kluczowe aspekty technologiczne, konstrukcyjne oraz produkcyjne urządzenia. Dokumentacja ta jest niezbędna do potwierdzenia zgodności urządzenia z europejskimi normami bezpieczeństwa oraz do zapewnienia jego prawidłowego użytkowania i dalszego rozwoju.

W skład opracowanych dokumentów wchodzi szczegółowy opis technologii, uwzględniający budowę i zasadę działania urządzenia, z naciskiem na drogę optyczną oraz zjawiska fizyczne zachodzące w układzie spektrometrycznym. Dzięki temu możliwe jest pełne zrozumienie sposobu generowania i przetwarzania widma odbiciowego, co ma kluczowe znaczenie dla poprawności pomiarów.


Drugim istotnym elementem dokumentacji jest szczegółowy opis algorytmów przetwarzających dane z sensora, które konwertują surowe sygnały optyczne na użyteczne dane spektralne. Opis obejmuje m.in. metody kalibracji, eliminację szumów, korekcję efektów optycznych oraz przekształcanie danych w wartości liczbowe nadające się do analizy agronomicznej. Dzięki temu dokumentowi możliwe jest nie tylko zrozumienie działania algorytmów, ale także ich przyszłe usprawnienia i dostosowanie do nowych wersji sprzętu.

Kolejnym kluczowym elementem jest szczegółowy opis produkcji i montażu urządzenia, zawierający instrukcje dotyczące procesów składania, kalibracji oraz kontroli jakości. Opracowanie tego dokumentu ma na celu standaryzację produkcji, zwiększenie powtarzalności parametrów pomiarowych oraz zapewnienie długoterminowej niezawodności urządzenia. Uwzględniono w nim także wytyczne dotyczące procedur serwisowych oraz ewentualnych poprawek technicznych, które mogą być wymagane w trakcie eksploatacji.




Introduction.....	2
Signal path overview.....	3
Effects of each part on the signal.....	3
Light source.....	3
Key takeaways:.....	9
Built-in reference.....	9
Thin slit.....	10
Diffraction grating.....	12
Key takeaways:.....	18
Camera lens.....	18
Key takeaways:.....	19
Camera sensor.....	19
Key takeaways:.....	23
Fixing the signal.....	23
Terminology.....	23
Loading up the raw.....	25
Detecting the grating angle.....	25
Calibration image.....	25
Scan image.....	26
Straightening the image.....	27
Calibration peaks.....	27
Finding the low peak.....	29
Finding the high peak.....	30
Conical diffraction.....	30
X axis correction.....	33
Black level correction.....	33
Final processing.....	33

Rys. 5.2.1. Spis treści dokumentacji technicznej dotyczącej drogi optycznej i przetwarzania sygnału przygotowanej w ramach projektu.




Rys. 5.2.2. Część schematu działania urządzenia scan spectrum zaprezentowany w dokumentacji technicznej.

Top view



Rys. 5.2.3. Część dokumentacji technicznej dotycząca obliczeń drogi optycznej, obrazu rzeczywistego oraz obrazu pozornego.



Rys. 5.2.4. Fragment instrukcji montażowej najnowszej wersji urządzenia ScanSpectrum.




SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO

5.3. Analiza danych z obydwu sezonów pomiarowych

W etapie 4 przeprowadzono szczegółową analizę danych zebranych podczas dwóch sezonów pomiarowych. W pierwszym sezonie wykorzystano wersję urządzenia oznaczoną jako v3, natomiast w drugim sezonie pomiary były realizowane zarówno za pomocą v3, jak i ulepszonej wersji v4. Nowe urządzenie (v4) zostało wyposażone w usprawniony sensor, co miało na celu poprawę jakości i czasu pomiaru zbieranych danych.

Jednym celów analiz z drugiego sezonu było sprawdzenie kompatybilności danych uzyskiwanych z obydwu wersji urządzeń oraz ocena wpływu jakości danych na efektywność budowania modeli predykcyjnych. Analizowano, czy większa ilość danych o gorszej jakości (v3) może być bardziej wartościowa od mniejszej ilości danych o wyższej jakości (v4), czy odwrotnie.


Na wykresach zamieszczonych poniżej widać wyraźne różnice w gładkości linii spektralnych, świadczące o odmiennej jakości sygnału – w szczególności o różnicy w stosunku sygnału do szumu między v3 a v4. Wersja v4 charakteryzuje się wyraźnie wyższym stosunkiem sygnału do szumu, co przełożyło się na bardziej stabilne i powtarzalne wyniki pomiarowe. Zaprezentowano również wyniki analiz, które obejmują budowanie modeli predykcyjnych nie tylko dla zawartości azotu w roślinach, ale również dla potasu i fosforu. Celem było określenie potencjału wykorzystania pomiarów spektrometrii odbiciowej również w kontekście detekcji niedoborów innych kluczowych makroelementów.



Rys. 5.3.1. Spektrogramy odbiciowe roślin pszenicy pokolorowane w zależności od kampanii pomiarowej.




Analogicznie do analiz wykonywanych w poprzednim sezonie pomiarowym, oprócz metod statystycznych filtracja danych odbywała się również poprzez graficzną prezentację i wyszukiwanie próbek odstających. Na wykresach powyżej dane są już po filtracji. Porównanie pokazuje również, że dane dla każdej z kampanii mają podobne charakterystyki niezależnie od użytej wersji urządzenia.




Rys. 5.3.2. Spektrogramy odbiciowe roślin pszenicy pokolorowane w zależności od rzeczywistej zawartości azotu w przeliczeniu na suchą masę.


Dla obydwu przypadków - v3 jak i v4 widać charakterystyczne gradienty związane ze zmianą zawartości azotu w roślinach. Prawie dwukrotnie większa ilość danych dla v3 ze względu na dwa sezony pomiarowe może być znacząca przewagą przy budowaniu modeli predykcyjnych, co zostanie zweryfikowane w dalszych analizach.



Rys. 5.3.3. Dystrybucja zawartości azotu dla drugiego sezonu pomiarowego. Lewy - pszenica, środkowy - rzepak, prawy - jęczmień.



Rys. 5.3.4. Dystrybucja zawartości potasu dla drugiego sezonu pomiarowego. Lewy - pszenica, środkowy - rzepak, prawy - jęczmień.



Rys. 5.3.5. Dystrybucja zawartości fosforu dla drugiego sezonu pomiarowego. Lewy - pszenica, środkowy - rzepak, prawy - jęczmień.

Analiza histogramów potwierdza szeroką dystrybucję makroelementów w próbkach, które przebadano podczas drugiego sezonu pomiarowego. Szeroki zakres wartości zapewnia odpowiednią reprezentację wszystkich możliwych przypadków. Model wyszkolony na szerokim zakresie będzie działał tak samo dobrze dla niedoborów, wartości optymalnych jak i wartości zawyżonych. W przypadku azotu, na którym głównie skupiamy się podczas naszych prac, nadreprezentacja w niskim zakresie dla jęczmienia i przerwa dla wartości średnich, może sprawić kłopot z wynikami w przypadku tej rośliny - tutaj model łączony z 2 sezonów może poprawić ten zbiór danych.


Przed testowaniem modeli uczenia maszynowego zestawy danych były dzielone na zbiory treningowe i testowe w stosunku 80% do 20%. Oznacza to, że 80% próbek było wykorzystywanych do budowania i uczenia modeli predykcyjnych, a pozostałe 20% służyło do ich niezależnej oceny i walidacji. Podczas podziału danych szczególną uwagę zwracano na to, aby rozkład wartości prognozowanego analitu – czyli zawartości azotu (N), fosforu (P) lub potasu (K) był podobny w obu zbiorach. Dzięki temu zapewniono, że zarówno zbiór treningowy, jak i testowy były reprezentatywne dla całego zakresu zmienności badanego parametru. Takie podejście minimalizuje ryzyko uzyskania nierealistycznych wyników, które mogłyby wynikać np. z przypadkowego przypisania ekstremalnych wartości tylko do jednego ze zbiorów. Zachowanie podobnej dystrybucji wartości analitów w obu zestawach danych jest kluczowe, aby rzetelnie ocenić, jak dobrze model generalizuje na nowych, nieznanach wcześniej próbkach, a nie tylko na danych, na których był trenowany.




SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO

Podobnie jak w przypadku pierwszego sezonu pomiarowego, również w drugim sezonie przetestowano wiele różnych modeli predykcyjnych oraz szeroki zakres zestawów hiperparametrów. Poniżej przedstawione wyniki odnoszą się wyłącznie do tych modeli, które osiągnęły najlepsze rezultaty, czyli wykazały się największą skutecznością w wykrywaniu istotnych cech spektralnych związanych z analizowanym parametrem. Dla naszego zbioru danych, metoda ET(Extra Trees) osiągała najlepsze wyniki.


Na zamieszczonych wykresach przedstawiono wyniki predykcji wykonanej na zbiorze testowym – to znaczy na próbkach, które nie były wykorzystywane podczas trenowania modelu. Takie podejście odzwierciedla rzeczywisty sposób zastosowania modelu w terenie, gdzie urządzenie dokonuje predykcji na nowych, wcześniej nieznanach danych.




Rys. 5.3.6. Wyniki predykcji azotu zestawione z pomiarem laboratoryjnym dla danych z wersji v4, lewy - pszenica, środkowy - rzepak, prawy - jęczmień. Sezon 2024.




Rys. 5.3.7. Wyniki predykcji potasu zestawione z pomiarem laboratoryjnym dla danych z wersji v4, lewy - pszenica, środkowy - rzepak, prawy - jęczmień. Sezon 2024.




Rys. 5.3.8. Wyniki predykcji fosforu zestawione z pomiarem laboratoryjnym dla danych z wersji v4, lewy - pszenica, środkowy - rzepak, prawy - jęczmień. Sezon 2024.




Rys. 5.3.9. Wyniki predykcji azotu zestawione z pomiarem laboratoryjnym dla danych z wersji v3, lewy - pszenica, środkowy - rzepak, prawy - jęczmień. Sezon 2024.




Rys. 5.3.10. Wyniki predykcji potasu zestawione z pomiarem laboratoryjnym dla danych z wersji v3, lewy - pszenica, środkowy - rzepak, prawy - jęczmień. Sezon 2024.



Rys. 5.3.11. Wyniki predykcji fosforu zestawione z pomiarem laboratoryjnym dla danych z wersji v3, lewy - pszenica, środkowy - rzepak, prawy - jęczmień. Sezon 2024.




Rys. 5.3.13. Wyniki predykcji azotu zestawione z pomiarem laboratoryjnym dla danych z wersji v3, lewy - pszenica, środkowy - rzepak, prawy - jęczmień. Sezony 2023 i 2024.



Rys. 5.3.14. Wyniki predykcji potasu zestawione z pomiarem laboratoryjnym dla danych z wersji v3, lewy - pszenica, środkowy - rzepak, prawy - jęczmień. Sezony 2023 i 2024.



SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO




Rys. 5.3.15. Wyniki predykcji fosforu zestawione z pomiarem laboratoryjnym dla danych z wersji v3, lewy - pszenica, środkowy - rzepak, prawy - jęczmień. Sezony 2023 i 2024.

Oprócz modeli dedykowanych dla konkretnych gatunków roślin, takich jak rzepak, pszenica czy jęczmień, przetestowano również modele ogólne, obejmujące wszystkie trzy gatunki jednocześnie. W tym celu dane pomiarowe ze wszystkich roślin zostały połączone w jeden wspólny zbiór, co znacząco zwiększyło różnorodność spektralną oraz zakres wartości analizowanych parametrów. Wspólny zbiór obejmuje zarówno różne morfologie liści, jak i szeroką zmienność wartości azotu, fosforu i potasu, co stanowiło dodatkowe wyzwanie, ale jednocześnie zwiększyło potencjalną odporność modelu na zmiany warunków terenowych i różnice między uprawami.

Z naukowego punktu widzenia, budowa uniwersalnego modelu predykcyjnego dla azotu jest uzasadniona ze względu na fundamentalną rolę azotu w fizjologii roślin. Azot jest kluczowym składnikiem chlorofilu – barwnika odpowiedzialnego za fotosyntezę – oraz podstawowym elementem budulcowym białek i kwasów nukleinowych. Z tego powodu zawartość azotu w liściach jest ściśle powiązana z właściwościami optycznymi tkanek roślinnych, w szczególności z ich zdolnością do pochłaniania i odbijania światła w zakresie widzialnym i bliskiej podczerwieni.

W związku z tym, choć różne gatunki roślin różnią się morfologią i strukturą liści, to zmiany w zawartości azotu wpływają na spektralne cechy odbiciowe w sposób częściowo uniwersalny. Dzięki temu istnieje realna możliwość zbudowania modelu spektralnego, który będzie w stanie prawidłowo estymować poziom azotu niezależnie od gatunku rośliny, wykorzystując wspólne, biologicznie uzasadnione mechanizmy wpływające na widmo odbiciowe.


W pierwszej kolejności przeprowadziliśmy analizę modeli spektralnych opartych wyłącznie na danych z urządzenia v3, testując osobno modele dla każdego sezonu pomiarowego oraz model łączony, uwzględniający dane z obydwu sezonów jednocześnie. Obydwa sezony charakteryzowały się lekko rozbieżnymi zakresami wartości azotu, co wynikało ze stosowania różnych agrotechnik w poszczególnych sezonach. Dodatkowym wyzwaniem były nietypowe warunki pogodowe: ciepły grudzień w 2023 roku oraz przyspieszona wegetacja w 2024 roku, która rozpoczęła się około miesiąc wcześniej niż zwykle. Pomimo tych trudności, po połączeniu danych z obu sezonów udało się uzyskać zbiór o stosunkowo równomiernej dystrybucji wartości azotu, co jest istotne z punktu widzenia stabilności i generalizacji budowanych modeli predykcyjnych.



Rys. 5.3.16. Wyniki predykcji azotu zestawione z pomiarem laboratoryjnym dla danych z wersji v3, model łączony. Lewy - sezon 2023, środkowy - sezon 2024, prawy - łączone sezony 2023 i 2024.

Wszystkie 3 modele wykazały podobną korelację i podobny błąd determinacji zawartości azotu, korelacje na poziomie $R^2 = 0.75$ można ocenić na wysoką. Znaczące zwiększenie ilości danych nie wpłynęło znacząco na skuteczność modelu, sugeruje to że ilość danych w okolicach 200 próbek, przy zachowaniu odpowiedniej dystrybucji wartości może być wystarczające do nauczania dobrego jakościowo modelu.

Analiza danych zebranych za pomocą ulepszonych urządzeń w wersji v4 jednoznacznie wskazuje na wyższą jakość budowanych modeli predykcyjnych w porównaniu do modeli opartych na danych z wersji v3. Modele oparte na pomiarach wykonanych urządzeniem v4 osiągały lepsze wartości współczynnika determinacji (R^2), co świadczy o większej zgodności między wartościami rzeczywistymi a prognozowanymi. Jednocześnie odnotowano niższe wartości średniego bezwzględnego błędu.



Rys. 5.3.17. Wyniki predykcji makroelementów zestawione z pomiarem laboratoryjnym dla danych z wersji v4 z sezonu 2024, model łączony. Lewy - azot, środkowy - potas, prawy - fosfor.




SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO

Dla azotu, potasu i fosforu w modelu łączonym dla roślin w każdym przypadku uzyskano korelację R^2 powyżej 0.8, co jest bardzo dobrym wynikiem dla modelu ogólnego. Skoro model ogólny dla łączonego zbioru rzepaku, pszenicy i jęczmienia ma wysoką skuteczność, bazując na ogólnej fizjologii roślin, być może da się go zaadaptować też do innych rodzajów upraw, co zespół QED planuje przetestować w przyszłości i zwiększyć zakres użyteczności docelowego rozwiązania.

Lepsze wyniki modeli sugerują, że wyższa jakość danych pomiarowych – w szczególności niższy poziom szumu oraz szerszy zakres spektralny obejmujący dalsze fragmenty podczerwieni – ma istotny wpływ na skuteczność i stabilność modeli predykcyjnych. Usprawnienia w konstrukcji spektrometru, wprowadzone w trakcie projektu, wniosły więc znaczną wartość praktyczną.

Wyraźnie lepsza jakość modeli przekłada się nie tylko na wyższą dokładność predykcji, ale również na większą wiarygodność systemu w oczach użytkowników końcowych. Możliwość oferowania bardziej precyzyjnych i powtarzalnych wyników pomiarowych stanowi kluczowy element budowania zaufania rolników do naszego urządzenia oraz całego systemu monitorowania stanu upraw.

Przeprowadzono również analizę danych dotyczących zawartości suchej masy w kukurydzy i spektrogramów z obydwu wersji spektrometru – V3 oraz V4. Wyniki uzyskane w dwóch kolejnych sezonach były spójne i niezależne od wersji zastosowanego urządzenia, mimo że spektrometr V3 charakteryzował się wyższym poziomem szumu w sygnale. Kluczową rolę odegrał tutaj silny sygnał absorpcji wody w zakresie około 970 nm, który odpowiada za intensywne pochłanianie promieniowania przez cząsteczki wody w tkankach roślinnych. Dzięki wyraźnemu „pikowi wodnemu” nawet urządzenie o większym szumie umożliwia skuteczne wykrycie różnic w wilgotności roślin, co przełożyło się na wysoką zgodność w ocenie zawartości suchej masy. Analiza w tym zakresie potwierdziła dużą przydatność spektroskopii bliskiej podczerwieni do precyzyjnego szacowania momentu optymalnego zbioru kukurydzy na kiszonkę.



Rys. 5.3.18. Wyniki predykcji suchej masy w kukurydzy dla sezonu 2024, wersja v4.




SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO

Model predykcji zawartości suchej masy został zintegrowany w systemie webowym aplikacji do monitorowania upraw. W przypadku wyboru kukurydzy jako uprawy, zamiast standardowej mapy zasobności azotu generowana jest mapa przedstawiająca rozkład suchej masy na polu. Dodatkowo wynik suchej masy jest prezentowany bezpośrednio w aplikacji mobilnej podczas skanowania roślin, co umożliwia użytkownikowi natychmiastową ocenę stanu uprawy w terenie i podejmowanie szybkich decyzji agrotechnicznych.

5.4. Wdrożenie modeli i systemu map nawożenia

W ramach projektu zostało przygotowane i wdrożone środowisko produkcyjne do generowania map nawożenia, które następnie zostało przetestowane we współpracy z rolnikami. System jest dostępny poprzez specjalny odnośnik zatytułowany „ScanSpectrum – Mapy nawozowe”, umieszczony na oficjalnej stronie internetowej projektu: qed.ai/scanspectrum.

Po przejściu do tego odnośnika i zalogowaniu się na indywidualne konto użytkownika, rolnik otrzymuje instrukcję krok po kroku, dotyczącą pobrania i instalacji aplikacji mobilnych: ScanSpectrum (główna aplikacja pomiarowa) oraz ScanSpectrum Collect (aplikacja pomocnicza do zbierania danych terenowych). Instrukcja obejmuje zarówno kwestie techniczne (instalacja, logowanie), jak i opis podstawowych funkcji obu aplikacji, umożliwiających kompleksowe wsparcie procesu zbierania danych polowych i tworzenia zaleceń nawozowych. Wdrożenie środowiska na serwerze produkcyjnym oraz testy w warunkach rzeczywistych z rolnikami pozwoliły na praktyczną weryfikację działania całego systemu, od rejestracji danych w polu aż po wygenerowanie map nawożenia, możliwych do wgrania do terminalu rozsiewacza.



Rys. 5.4.1. Ekran powitalny po pierwszym zalogowaniu w systemie „ScanSpectrum - Mapy nawozowe”.




SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO

Przy pierwszym uruchomieniu aplikacji ScanSpectrum Collect, użytkownik skanuje kod QR dostępny w interfejsie webowym systemu. Kod ten umożliwia przypisanie wcześniej wgranych pól uprawnych do aplikacji mobilnej, co pozwala na dalszą pracę bez konieczności ręcznego wprowadzania informacji o lokalizacjach.

W terenie praca rozpoczyna się od podłączenia urządzenia ScanSpectrum do smartfona oraz uruchomienia aplikacji ScanSpectrum Collect. Następnie użytkownik wybiera z listy pole, na którym aktualnie pracuje. Przed wykonaniem pomiarów system prosi o wypełnienie krótkiej ankiety dotyczącej aktualnego stanu upraw: użytkownik wskazuje fazę rozwoju roślin w miejscu pomiaru, gęstość obsady roślin oraz ewentualne objawy stresu roślin. Aplikacja pozwala również na sfotografowanie punktu i dostępu do podglądu na punkcie w interfejsie online.

Po uzupełnieniu tych danych aplikacja automatycznie przekierowuje użytkownika do trybu pomiarowego, gdzie rozpoczyna się właściwy proces skanowania. Zgodnie z instrukcjami pomiarowymi użytkownik wykonuje odpowiednią liczbę skanów w obrębie wyznaczonego punktu.

Po zakończeniu wymaganej liczby pomiarów, dane są automatycznie przesyłane na serwer, gdzie stają się natychmiast dostępne w widoku webowym. Platforma internetowa umożliwia bieżący podgląd postępów kampanii pomiarowej, w tym rozmieszczenia wykonanych oraz zaplanowanych punktów pomiarowych na mapie.




Rys. 5.4.2. Widoki aplikacji mobilnej "ScanSpectrum Collect", inicjalizacja i uruchomienie pomiaru.



SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO

The figure shows three sequential screenshots of the 'ScanSpectrum Collect' mobile application interface, all for a location named 'Parczew 5'.
1. The first screen, titled 'Faza wzrostu' (Growth stage), lists five radio button options: '13 - 19 Wzrost liści / rozeta', '20 - 29 Rozwój pędów bocznych / krzewienie', '30 - 36 Początek wydłużania łodygi / strzelanie w źdźbło', '37 - 45 Liść flagowy / rozrastanie pędu generatywnego', and '50 - 59 Przed kwitnieniem'.
2. The second screen, titled 'Gęstość roślin w punkcie' (Plant density at the point), lists three radio button options: 'Rzadkie', 'Średnie', and 'Gęste' (which is selected).
3. The third screen, titled 'Stres roślin' (Plant stress), lists ten checkboxes for various stress factors: 'Susza', 'Nadmiar wody', 'Przymrozki', 'Upał', 'Gradobicie', 'Silny wiatr', 'Niedobory składników pokarmowych', 'Choroba grzybowa', 'Choroba bakteryjna', 'Choroba nieokreślona', 'Szkodniki', and 'Chwasty'.
Each screen has navigation buttons at the bottom: '< Powrót' and 'Następny >'.

Rys. 5.4.3. Widoki aplikacji mobilnej "ScanSpectrum Collect", ankieta dotycząca stanu upraw.




Rys. 5.4.4. Widoki aplikacji mobilnej "ScanSpectrum Collect", możliwość zrobienia zdjęcia w punkcie i przejście do trybu pomiarów spektralnych.



SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO

Interfejs webowy systemu ScanSpectrum oferuje szereg funkcji umożliwiających zarządzanie danymi pomiarowymi oraz generowanie map nawożenia. Użytkownik ma możliwość podejrzenia wartości azotu zmierzonych w poszczególnych punktach pomiarowych rozmieszczonych na mapie pola. Na podstawie zebranych danych system umożliwia następnie wygenerowanie mapy zasobności azotu dla całego pola, a następnie podzielenie jej na sektory zasobności i wygenerowanie map nawożenia. Po ustaleniu dawek nawozu dla poszczególnych stref, możliwe jest automatyczne wygenerowanie pliku mapy do rozsiewacza nawozu. Proces generowania analizuje wszystkie punkty w obrębie pola, przypisuje wagi do punktów w zależności od stresów roślinnych, fazy rozwojowej i gęstości uprawy, co zwiększa precyzję mapy aplikacyjnej.



Rys. 5.4.5. Widok pola w interfejsie webowym - system umożliwia podejrzenie zawartości azotu i zdjęć na punktach pomiarowych oraz wygenerowanie mapy.



SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO

ScanSpectrum – Mapy nawozowe

Innowacje w polskim rolnictwie

O projekcie


Wyloguj się

[← Powrót do szczegółów kampanii](#)

Generowanie mapy nawożenia dla Parczew 5

Obszar pola: 10,26 ha

Mapa pola



Nawozenie azotem (N):
● Granica pola
Niskie Wysokie

Parametry nawożenia

Typ nawozu

Saletra amonowa

Cena nawozu (PLN/t)

2000

Minimalna dawka nawozu (kg/ha)

100

Maksymalna dawka nawozu (kg/ha)

300

Przypisanie dawek do regionów

Czerwony region (kg/ha): 300 24.7%

Żółty region (kg/ha): 200 46.5%

Zielony region (kg/ha): 100 28.9%

Kalkulacja kosztów

Koszt przy maksymalnej dawce na całe pole: 6158.71 PLN

Szacowana oszczędność przy zmiennym dawkowaniu: 2139.61 PLN

Format pliku

Format pliku

CSV (uniwersalny)

[Generuj i pobierz mapę](#)

⚠ Wygenerowana mapa nawożenia jest przeznaczona do użytku z kompatybilnymi systemami rolnictwa precyzyjnego. Przed zastosowaniem w terenie, zaleca się konsultację z agronomek.

Rys. 5.4.4. Widok generowania mapy nawożenia w interfejsie webowym. System liczy oszczędność z zastosowania zmiennej dawki względem dawki maksymalnej na całym polu.



SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO

System ScanSpectrum umożliwia generowanie map nawożenia azotowego w formatach zgodnych z popularnymi modelami rozsiewaczy oraz ich terminalami sterującymi, co pozwala na bezpośrednie wykorzystanie map w maszynach rolniczych wyposażonych w technologię precyzyjnego rolnictwa. Oprócz obsługi konkretnych modeli, dostępne są również formaty uniwersalne, które mogą zostać przekonwertowane do wymaganego formatu za pomocą oprogramowania dołączonego do terminala danego rozsiewacza.

Mapy generowane na podstawie pomiarów wykonanych jesienią na uprawach ozimych, w ich wczesnych fazach rozwojowych, mogą być z powodzeniem wykorzystane do planowania nawożenia azotowego wiosną. Umożliwia to lepsze dostosowanie dawek do rzeczywistego stanu roślin przed wejściem w fazy intensywnego wzrostu.

W przypadku upraw jarych, pomiary wykonane w sezonie wegetacyjnym mogą posłużyć do weryfikacji skuteczności nawożenia głównego oraz do optymalizacji dawek nawożenia pogłównego, czyli stosowanego w późniejszych fazach wzrostu.

Ponadto, pomiary wykonane po zastosowaniu nawozu mogą mieć wartość monitorującą, pozwalając ocenić skutki wcześniejszych decyzji nawozowych i zebrać dane przydatne do planowania strategii nawożenia w kolejnym sezonie. Tym samym system wspiera zarówno bieżące zarządzanie nawożeniem, jak i długoterminową optymalizację gospodarowania azotem.



SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO

6. Podsumowanie projektu

Projekt „ScanSpectrum – innowacja w polskim rolnictwie”, współfinansowany ze środków Unii Europejskiej w ramach działania „Współpraca”, został zakończony z sukcesem. Wszystkie założone cele zostały spełnione, a uzyskane wyniki otwierają nowe możliwości dla rolnictwa precyzyjnego. W ciągu dwóch lat intensywnych prac badawczo-rozwojowych, obejmujących eksperymenty terenowe, zbieranie i analizę danych, a także rozwój technologii, udało się dopracować zarówno samo urządzenie, jak i cały proces produkcyjny. Dzięki szeregowi nowych programów, algorytmów oraz aplikacji mobilnych ScanSpectrum stało się kompletnym rozwiązaniem gotowym do wdrożenia, dostosowanym do rzeczywistych potrzeb rolników i badaczy. Opinie użytkowników zebrane podczas testów terenowych pozwoliły na dopasowanie funkcjonalności urządzenia do codziennej pracy w gospodarstwach rolnych, co zwiększyło jego użyteczność i intuicyjność obsługi.

Szczególnym osiągnięciem projektu było opracowanie algorytmów predykcyjnych opartych na uczeniu maszynowym, które pozwalają na określenie zawartości azotu w roślinach z dokładnością zbliżoną do wyników analizy laboratoryjnej OSCHR. W tradycyjnym podejściu analiza jednej próbki roślinnej kosztuje około 70 zł, a czas oczekiwania na wynik wynosi 6-8 tygodni. ScanSpectrum pozwala na wykonanie 40 pomiarów w polu w przeciągu kilku godzin, co sprawia, że zwrot kosztów zakupu urządzenia następuje już po kilkudziesięciu pomiarach. Jest to znaczący przełom w zakresie szybkości i dostępności analiz, co umożliwia rolnikom natychmiastowe podejmowanie decyzji dotyczących nawożenia bez konieczności długiego oczekiwania na wyniki laboratoryjne.

Opracowane zostały również modele predykcyjne dla suchej masy kukurydzy, które umożliwiają tworzenie map wilgotności pola, precyzyjne określenie średniej wilgotności plonu oraz prognozowanie najlepszych momentów zbioru. Możliwość analizy wilgotności w czasie rzeczywistym pozwala rolnikom lepiej planować harmonogram zbiorów, unikać strat związanych z nieodpowiednią wilgotnością kiszonki oraz optymalizować suszenie plonu, co przekłada się na realne oszczędności. Precyzyjne mapy wilgotności mogą być również wykorzystywane do precyzyjnego sterowania procesami zbioru i przetwarzania kukurydzy, co znacząco wpływa na efektywność gospodarowania plonem.

Dodatkowo opracowane eksperymentalne modele predykcyjne dla zawartości potasu i fosforu wykazały wysoką skuteczność, otwierając drogę do dalszego rozwoju i wdrożenia technologii także w tym zakresie. Możliwość szybkiego i nieniszczącego określania poziomu tych składników odżywczych w roślinach pozwala na lepsze zarządzanie nawożeniem i dostosowanie dawek do rzeczywistych potrzeb upraw. Dzięki temu możliwe będzie zwiększenie efektywności nawożenia, redukcja kosztów oraz minimalizacja wpływu na środowisko poprzez ograniczenie nadmiernej aplikacji nawozów.



SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO

Ostateczne wdrożone wyniki dokładności najlepszych wybranych modeli przewidywania spektralnego przedstawiono w tabeli. Współczynnik R^2 równy 1 jest idealną możliwością predykcyjną, powyżej 0.7 uznaje się korelację za wysoką, powyżej 0.9 jest to wynik na poziomie błędów pomiarów laboratoryjnych.

Roślina	Azot	Potas	Fosfor	Sucha masa
Pszenica	$R^2=0.91$	$R^2=0.81$	$R^2=0.94$	-
Rzepak	$R^2=0.95$	$R^2=0.77$	$R^2=0.8$	-
Jęczmień	$R^2=0.78$	$R^2=0.84$	$R^2=0.64$	-
Kukurydza	-	-	-	$R^2=0.74$, MAE=0.04
Model ogólny	$R^2=0.81$ MAE=0.36	$R^2=0.8$ MAE = 0.45	$R^2=0.8$ MAE = 0.05	

Operacja została zakończona sukcesem, osiągając wszystkie zakładane cele związane z wdrożeniem ulepszonej innowacji technologicznej i organizacyjnej. W ramach innowacji technologicznej opracowano nowe oraz ulepszone współczynniki kalibracji dla roślin uprawnych oraz względem standardowych urządzeń typu N-tester, umożliwiające dokładne generowanie map nawożenia oraz pomiar zawartości suchej masy w roślinach kukurydzy. Dzięki temu możliwe jest precyzyjne wysiewanie azotu według zapotrzebowania roślin na konkretnych obszarach pól oraz optymalne określanie terminów zbioru kukurydzy na kiszonkę, co pozwala na uzyskanie paszy o wysokich właściwościach odżywczych i efektywniejszy proces zakiszania. W ramach innowacji organizacyjnej udoskonalono procesy nawożenia i produkcji paszowej poprzez wykorzystanie urządzenia QED, umożliwiającego automatyczne zbieranie danych polowych i ich przekazywanie do bazy danych bez konieczności ręcznego zapisywania wyników. Aplikacja na bieżąco tworzy mapy pola z oznaczeniem zasobności roślin w azot oraz generuje plany nawożenia, uwzględniając zapotrzebowanie roślin na poszczególnych fragmentach pól. Rezultaty te pozwoliły na zmniejszenie kosztów produkcji, kosztów zarządzania oraz kosztów środowiskowych poprzez ograniczenie zużycia nawozów i emisji gazów cieplarnianych. Operacja wpłynęła także na wyrównanie plonu pod względem jakościowym, podniesienie jakości otrzymywanej kiszonki, poprawę wartości pokarmowej paszy oraz zmniejszenie ryzyka jej psucia się podczas procesu zakiszania. Ponadto wdrożone rozwiązania przyczyniły się do zwiększenia poziomu innowacyjności branży rolnej w Polsce, poprawy ochrony środowiska oraz łagodzenia efektów zmian klimatu. Opracowane technologie i urządzenia, wyróżniające się unikalnymi cechami na polskim rynku, stanowią istotny krok w stronę cyfryzacji i precyzyjnego zarządzania produkcją rolniczą.



SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO

Projekt ScanSpectrum pokazał, że spektrometria odbiciowa w połączeniu z zaawansowaną analizą danych i uczeniem maszynowym może zrewolucjonizować rolnictwo precyzyjne. Stworzone rozwiązanie jest szybszą, tańszą i równie dokładną alternatywą dla standardowych metod laboratoryjnych, umożliwiającą rolnikom natychmiastowy dostęp do kluczowych informacji o stanie upraw. Uzyskane wyniki stanowią solidną podstawę do dalszego rozwoju technologii oraz rozszerzenia jej zastosowań na kolejne aspekty analizy rolniczej.

Wyniki projektu ScanSpectrum - Innowacja w Polskim Rolnictwie zostały zaprezentowane na IX Forum Wiedzy i Innowacji w Rolnictwie, gdzie spotkały się czołowe instytucje badawcze, rolnicy oraz przedstawiciele branży agro. W kontekście optymalizacji nawożenia azotowego, urządzenie zostało wyróżnione jako najciekawsze innowacyjne rozwiązanie w rolnictwie, zdobywając pierwsze miejsce w konkursie oraz nagrodę pieniężną w wysokości 6000 złotych. Uczestnicy forum docenili przede wszystkim praktyczne zastosowanie technologii w rolnictwie precyzyjnym, jej potencjał w redukcji kosztów nawożenia oraz możliwość szybkiej analizy stanu upraw.



Rys. 6.1.1. Stanowisko wystawiennicze ScanSpectrum na IX Forum Wiedzy i Innowacji w Rolnictwie




SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO



Rys. 6.1.2. Zespół QED Poland odbiera nagrodę za zdobycie pierwszego miejsca w konkursie "Najciekawsze innowacyjne rozwiązania w rolnictwie" na IX Forum Wiedzy i Innowacji w Rolnictwie.

Część wyników z badań dotyczących wytwarzania map nawożenia na podstawie pomiarów spektralnych została zaprezentowana podczas 51. Przeglądu Kół Naukowych SGGW przez koło naukowe rolników, gdzie zdobyła pierwsze miejsce w konkursie na najlepszy projekt badawczy. Prezentacja skupiała się na praktycznym wykorzystaniu ScanSpectrum w analizie stanu odżywienia roślin oraz jego potencjale w optymalizacji nawożenia pszenicy i rzepaku. Jury doceniło zarówno nowatorskie podejście do analizy spektralnej, jak i precyzyjnie opracowane metody badawcze, które pozwoliły uzyskać wyniki zbliżone do kosztownych analiz laboratoryjnych.



Rys. 6.1.3. Plakat prezentujący wyniki badań na 51 Przeglądzie Kół Naukowych SGGW oraz dyplom za otrzymanie pierwszego miejsca.



SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO

7. Rekomendacja dalszych działań

Na podstawie ogółu działań konsorcjum oraz wewnętrznych rozmów stwierdzono, że projekt ma pełne spektrum możliwości rozwoju.

1. Walidacja i rozszerzenie zastosowań na nowe gatunki roślin

Dalszy rozwój projektu ScanSpectrum powinien koncentrować się na walidacji modeli predykcyjnych dla szerokiego zakresu gatunków roślin uprawnych. Dotychczasowe działania potwierdziły skuteczność analizy wybranych parametrów w podstawowych uprawach, jednak rozszerzenie badań na takie rośliny jak soja, burak cukrowy, rzepak, kukurydza czy trawy pastewne mogłoby znacząco zwiększyć uniwersalność technologii. Walidacja modeli w zróżnicowanych warunkach agronomicznych i na różnych gatunkach pozwoliłaby na stworzenie wszechstronnych algorytmów predykcyjnych, które mogłyby być wdrażane w różnych sektorach rolnictwa, zarówno w dużych gospodarstwach towarowych, jak i mniejszych gospodarstwach mieszanych. Dodatkowo, uwzględnienie w analizach związków bioaktywnych oraz parametrów jakościowych (np. zawartości polifenoli, antyoksydantów) umożliwiłoby wykorzystanie ScanSpectrum w uprawach specjalistycznych, takich jak rośliny zielarskie czy uprawy przeznaczone na cele przemysłu spożywczego i farmaceutycznego. Tego typu działania wpisują się w koncepcję zrównoważonego rolnictwa i rosnącego zapotrzebowania na precyzyjne narzędzia analityczne.

2. Rozwój modeli predykcyjnych plonu – aspekt ilościowy i jakościowy

Jednym z kluczowych kierunków rozwoju ScanSpectrum jest budowa zaawansowanych modeli predykcyjnych, które umożliwiłyby prognozowanie zarówno ilości, jak i jakości plonu. Wykorzystanie danych spektralnych w połączeniu z informacjami zbieranymi przez systemy monitorujące pracę maszyn rolniczych (np. mapy plonów generowane przez kombajny wyposażone w czujniki NIR) pozwoliłoby na stworzenie kompleksowego narzędzia wspierającego zarządzanie uprawami. Predykcja parametrów takich jak zawartość białka, suchej masy, cukrów czy innych wskaźników jakościowych mogłaby znacząco poprawić efektywność gospodarowania zasobami oraz zwiększyć dochodowość produkcji. Tego typu modele umożliwiłyby optymalizację zabiegów agrotechnicznych jeszcze w trakcie sezonu wegetacyjnego, co pozwoliłoby na lepsze dostosowanie nawożenia, nawadniania czy ochrony roślin do przewidywanych wyników produkcyjnych. Rozwój takich funkcjonalności mógłby przyczynić się do popularyzacji rolnictwa precyzyjnego wśród polskich rolników, oferując im realne korzyści ekonomiczne oraz środowiskowe.



SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO

3. Adaptacja technologii do oceny jakości produktów rolnych i spożywczych

Technologia ScanSpectrum posiada duży potencjał w zakresie zastosowania poza samą produkcją rolną, szczególnie w sektorze oceny jakości produktów spożywczych. Rozszerzenie funkcjonalności spektrofotometru o możliwość analizy parametrów jakościowych mięsa, mleka, przetworów zbożowych czy kiszonek mogłoby znaleźć szerokie zastosowanie w przemyśle spożywczym oraz paszowym. Dzięki szybkim, bezkontaktowym pomiarom możliwe byłoby efektywne monitorowanie zawartości białka, tłuszczu, wilgotności czy suchej masy w różnych produktach, co znacząco zwiększyłoby kontrolę jakości na każdym etapie produkcji i przetwórstwa. Tego typu rozwiązanie mogłoby również wspierać systemy HACCP oraz inne procedury zapewnienia bezpieczeństwa żywności, odpowiadając na rosnące wymagania konsumentów i regulatorów w zakresie transparentności i jakości produktów. Wdrożenie tej technologii w zakładach przetwórczych mogłoby przyczynić się do zwiększenia konkurencyjności firm działających w sektorze rolno-spożywczym poprzez automatyzację procesów kontrolnych i minimalizację ryzyka produkcji niezgodnej z normami.

4. Integracja z procesami przemysłowymi i przetwórczymi

Wdrożenie technologii ScanSpectrum bezpośrednio w liniach produkcyjnych i przetwórczych stanowi istotny kierunek rozwoju, który mógłby znacząco zwiększyć efektywność przemysłu rolno-spożywczego. Integracja spektrometrii z systemami automatyki przemysłowej umożliwiłaby bieżącą kontrolę jakości surowców oraz produktów końcowych w czasie rzeczywistym, bez konieczności przerywania procesu produkcyjnego. Dzięki temu możliwe byłoby szybkie wykrywanie niezgodności jakościowych, co pozwoliłoby na natychmiastową reakcję i minimalizację strat materiałowych oraz finansowych. Tego typu rozwiązania są zgodne z ideą Przemysłu 4.0, gdzie kluczową rolę odgrywają inteligentne systemy monitoringu i analizy danych. Wdrożenie ScanSpectrum w zakładach produkcyjnych mogłoby również wspierać realizację standardów jakościowych, takich jak ISO czy BRC, a także zwiększyć transparentność procesów wobec klientów i partnerów biznesowych. Automatyzacja kontroli jakości poprzez spektrofotometrię mogłaby stać się standardem w nowoczesnych zakładach przetwórczych, poprawiając ich konkurencyjność oraz zrównoważenie operacyjne.



SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO

5. Rozbudowa funkcjonalności o analizę gleby

Rozszerzenie możliwości ScanSpectrum o funkcję analizy gleby mogłoby zrewolucjonizować sposób monitorowania parametrów środowiskowych w gospodarstwach rolnych. Dzięki zastosowaniu spektrometrii do oceny takich wskaźników jak zawartość materii organicznej, wilgotność, pH, zasolenie czy poziom składników mineralnych, rolnicy mogliby uzyskać natychmiastowy dostęp do kluczowych informacji o stanie gleby, bez potrzeby czasochłonných i kosztownych badań laboratoryjnych. Tego typu mobilne rozwiązanie wpisuje się w potrzeby rolnictwa precyzyjnego, gdzie szybka diagnostyka pozwala na optymalizację zabiegów agrotechnicznych, takich jak nawożenie, wapnowanie czy irygacja. Regularne monitorowanie gleby w czasie rzeczywistym mogłoby również przyczynić się do poprawy zdrowotności gleb, zwiększenia ich żyzności oraz ograniczenia negatywnego wpływu intensywnej gospodarki rolnej na środowisko. Dodatkowo, tego typu funkcjonalność mogłaby wspierać rolników w spełnianiu wymogów związanych z praktykami ekologicznymi i zrównoważonym zarządzaniem zasobami naturalnymi, co jest szczególnie istotne w kontekście polityk unijnych.

6. Szybka analiza jakości nawozów naturalnych i organicznych

Zastosowanie ScanSpectrum do analizy jakości nawozów naturalnych i organicznych, takich jak obornik, gnojowica, komposty czy digestaty, mogłoby przynieść wymierne korzyści w zakresie optymalizacji nawożenia. Dzięki mobilnej i szybkiej diagnostyce możliwe byłoby precyzyjne określenie zawartości składników pokarmowych (m.in. azotu, fosforu, potasu) w stosowanych nawozach, co pozwoliłoby rolnikom na dostosowanie dawek do rzeczywistych potrzeb roślin oraz warunków glebowych. Takie podejście sprzyjałoby efektywnemu gospodarowaniu zasobami, zmniejszeniu kosztów produkcji oraz ograniczeniu ryzyka przenawożenia i zanieczyszczenia środowiska, szczególnie w zakresie ochrony wód przed eutrofizacją. Dodatkowo, tego typu technologia mogłaby wspierać realizację dobrych praktyk rolniczych oraz wdrażanie strategii związanych z gospodarką obiegu zamkniętego (GOZ), poprzez lepsze wykorzystanie nawozów organicznych pochodzących z produkcji zwierzęcej i biogazowni. Szybka walidacja jakości surowców nawozowych mogłaby również ułatwić rolnikom spełnianie norm i wymogów agri-environmentalnych oraz zwiększyć efektywność działań w ramach programów rolno-środowiskowych.



SZKOŁA GŁÓWNA
GOSPODARSTWA
WIEJSKIEGO

7. Zastosowanie w branży paszowej i produkcji zwierzęcej

Technologia ScanSpectrum mogłaby odegrać kluczową rolę w branży paszowej oraz w produkcji zwierzęcej, szczególnie w zakresie kontroli jakości pasz objętościowych, kiszzonek i mieszanek treściwych. Możliwość bieżącej analizy składu pasz, obejmującej parametry takie jak zawartość białka, włókna, tłuszczu, suchej masy czy energii metabolicznej, pozwoliłaby na dynamiczne dostosowanie dawek pokarmowych do aktualnych potrzeb zwierząt. Takie rozwiązanie mogłoby znacząco poprawić efektywność żywienia, ograniczyć straty paszowe oraz przyczynić się do poprawy zdrowotności i wydajności produkcji zwierzęcej. Dodatkowo, szybka diagnostyka składu pasz mogłaby wspierać kontrolę bezpieczeństwa żywności poprzez wykrywanie nieprawidłowości w surowcach i komponentach żywieniowych. Wprowadzenie spektrometrii do codziennej praktyki w gospodarstwach hodowlanych oraz w zakładach produkcji pasz mogłoby również wspierać działania na rzecz zrównoważonej produkcji zwierzęcej, optymalizując zużycie zasobów i ograniczając emisje związane z nadmiernym zużyciem pasz i nawozów.

8. Rozwój systemów wspierających decyzje rolnicze z wykorzystaniem AI

Ostatnim, ale niezwykle perspektywicznym kierunkiem rozwoju jest integracja ScanSpectrum z zaawansowanymi systemami analitycznymi opartymi na sztucznej inteligencji i uczeniu maszynowym. Połączenie danych spektralnych z danymi przestrzennymi (GIS), agrochemicznymi oraz meteorologicznymi mogłoby umożliwić budowę kompleksowych platform wspierających decyzje rolnicze (Decision Support Systems – DSS). Takie rozwiązania mogłyby przewidywać optymalne terminy zabiegów agrotechnicznych, sugerować dawki nawożenia, ostrzegać przed ryzykiem wystąpienia chorób czy szkodników, a także prognozować plony i jakość produkcji. Wdrożenie algorytmów AI zwiększyłoby precyzję i efektywność zarządzania gospodarstwem, minimalizując ryzyko oraz wspierając zrównoważony rozwój. Tego typu systemy mogłyby być dostosowane do potrzeb zarówno dużych przedsiębiorstw rolnych, jak i małych gospodarstw rodzinnych, dzięki modułowej budowie i skalowalności rozwiązań. Rozwój w tym kierunku wpisuje się w globalne trendy cyfryzacji rolnictwa oraz wykorzystania big data i AI w sektorze agro.