

## Badanie możliwości wykorzystania metod uczenia maszynowego do określenia przebiegu wydzielen klas bonitacyjnych

*Research for possibilities of using machine learning methods for  
defining soil valuation classes boundaries*

Michał SZKIBIEL

Warsaw University of Technology  
Faculty of Geodesy and Cartography  
[michal.szkibiell.dokt@pw.edu.pl](mailto:michal.szkibiell.dokt@pw.edu.pl)

Katarzyna OSIŃSKA-SKOTAK

Warsaw University of Technology  
Faculty of Geodesy and Cartography  
[katarzyna.osinska-skotak@pw.edu.pl](mailto:katarzyna.osinska-skotak@pw.edu.pl)

**Streszczenie:** W teledetekcji w ostatnich latach uzyskano duży postęp dzięki wprowadzeniu automatyzacji oraz zastosowaniu algorytmów sztucznej inteligencji. Nowe podejście pozwoliło wykryć zależności, które nie były widoczne dla człowieka i stał się możliwy analityczny opis rzeczywistości, który do tej pory głównie opierał się na intuicji. Jednym z wyzwań w zakresie teledetekcji gleb jest monitorowanie stanu gleb w skali kraju oraz aktualizacja baz danych o glebach, w tym aktualizacja przebiegu wydzielen klas bonitacyjnych. Celem niniejszych badań było sprawdzenie możliwości wykorzystania metod uczenia maszynowego do klasyfikacji gleb zgodnie z obowiązującą gleboznawczą klasyfikacją gruntów ornych z użyciem danych teledetekcyjnych i numerycznego modelu terenu (NMT). Jako dane źródłowe wykorzystano satelitarne obrazy optyczne Sentinel-2 i radarowe Sentinel-1 oraz cztery produkty pochodne NMT, opisujące cechy ważne z punktu widzenia klasyfikacji bonitacyjnej gleb. Klasyfikacje zostały przeprowadzone metodą lasów losowych i konwolucyjnych sieci neuronowych (CNN) na wybranym obszarze treningowym w różnych scenariuszach, a następnie wytrenowane modele zostały zweryfikowane na zestawie testowym. Niestety modele opisane lasami losowymi nie uzyskały dobrych wyników na zestawie testowym w przeciwieństwie do zestawu treningowego (skuteczność 70% vs 10%). Modele opisane przez CNN uzyskały wyniki podobne dla obu zestawów, lecz ich skuteczność była niska (40%)

**Abstract:** In recent years there was a large progress in remote sensing, thanks to applying automation and artificial intelligence algorithms. The new approach revealed relationships which were not visible for human operator and enabled analytical description of reality which was based on intuition so far. One of challenges of soil remote sensing is monitoring of soil condition in country scale and database actualisation including actualisation of soil valuation classes boundaries. The aim of the research was to find out possibilities of using machine learning methods for soil classification on arable land according to current Polish law with remote sensing data and digital elevation model (DEM). Used source data were optical satellite images of Sentinel-2 and radar of Sentinel-1, and four derived products of DEM describing significant features for soil valuation classification. Classification was done by random forests and convolutional neural networks (CNN) on selected training dataset in different scenarios and then trained models were verified on test dataset. Unluckily, models described by random forests were not successful on test dataset as much as on training dataset (accuracy 70% vs 10%). Models described by CNN had similar results for both datasets but the accuracy was low (40%)

**Słowa kluczowe:** teledetekcja gleb, uczenie maszynowe, gleboznawstwo, klasyfikacja bonitacyjna gleb

**Keywords:** soil remote sensing, machine learning, soil science, soil valuation class

## Wprowadzenie

Gleba jest wierzchnią warstwą Ziemi, która stanowi bardzo istotny element ekosystemu. Według Mocka (2015) glebę można zdefiniować jako „naturalną zewnętrzną warstwę litosfery (skorupy ziemskiej) ukształtowaną w wyniku integralnego oddziaływania klimatu i żywych organizmów na zwietrzelinę skalną (macierzysty materiał glebowy) w warunkach określonego reliefu, w ciągu pewnego przedziału czasu, przy wydatnym wpływie bezpośrednim bądź pośrednim gospodarczej działalności człowieka”.

Mocek (2015) wskazuje na następujące funkcje gleby: gleba magazynuje wodę opadową; jest również miejscem rozwoju drobnoustrojów, które decydują o odpowiednim krążeniu związków chemicznych w przyrodzie; w wierzchniej warstwie gleby odkłada się również warstwa próchnicza pochodząca z rozkładu cząstek organicznych, która jest największym biologicznie czynnym źródłem energii na Ziemi. Dzięki tym cechom, gleba jest podstawowym miejscem rozwoju podziemnych organów roślin, które za ich pomocą pobierają wodę i składniki mineralne, które są niezbędne do rozwoju roślin. Oznacza to, że jakość gleby jest kluczowa nie tylko dla przyrody, ale również i człowieka, gdyż nie tylko przesądza o rozwoju ekosystemów naturalnych, ale również ma duży wpływ na gospodarkę rolną, ponieważ właściwe gospodarowanie glebą może doprowadzić do zwiększenia plonów i zapewnienia bezpieczeństwa żywnościowego.

Gleby – w zależności od różnych cech – są różnie klasyfikowane (Polskie Towarzystwo Gleboznawcze, 2008). Jedną z systematyk jest klasyfikacja bonitacyjna, która odgrywa ważną rolę w polskim systemie prawnym (Rozporządzenie Ministra Rozwoju Regionalnego i Budownictwa z dnia 29 marca 2001 r. w sprawie ewidencji gruntów i budynków, Dz. U. 2019, poz. 393; Rozporządzenie Rady Ministrów z dnia 12 września 2012 r. w sprawie gleboznawczej klasyfikacji gruntów, Dz. U. 2012, poz. 1246). Obecnie obowiązująca klasyfikacja bonitacyjna gleb jest prowadzona od 1956 roku i zachowuje ciągłość prawną. Jest ona podstawowym kryterium oceny gleby pod względem ekonomicznym. Klasy bonitacyjne gleb są podstawą określania wysokości podatków, wyceny gruntów oraz mają znaczenie w procesie planowania przestrzennego. Klasyfikacji gruntów ornych dokonuje się przede wszystkim na podstawie typu gleby oraz następujących cech (Mocek 2015):

- położenie w terenie,
- budowa profilu,
- barwa,
- struktura,
- skład granulometryczny (zróznicowanie względem poziomów),
- przepuszczalność,
- stosunki wodne,
- odczyn,
- zawartość CaCO<sub>3</sub> (wapno).

Dla gruntów ornych Rozporządzenie Rady Ministrów z dnia 12 września 2012 r. w sprawie gleboznawczej klasyfikacji gruntów (Dz. U. 2012, poz. 1246) wyróżnia 9 klas (Tabela 1), przy czym klasa I określa grunty najbardziej urodzajne, a klasa VIz najmniej urodzajne.

Wykonanie gleboznawczej klasyfikacji gruntów metodą klasyczną jest jednak zadaniem czasochłonnym, gdyż wymaga dokonywania odwiertów w terenie oraz pomiaru wielu różnych cech gleb. Poszukiwane są zatem inne, alternatywne sposoby dokonywania aktualizacji map glebowo-rolniczych.

W teledetekcji w ostatnich latach uzyskano duży postęp dzięki wprowadzeniu automatyzacji oraz zastosowaniu algorytmów sztucznej inteligencji. Nowe podejście pozwoliło wykryć zależności, które nie były widoczne dla człowieka i stał się możliwy analityczny opis rzeczywistości, który do tej pory głównie opierał się na intuicji. Zaczęto podejmować próby identyfikacji różnych cech gleb, a wiele z nich zakończyło się sukcesem. Okazuje się, że z pułapu satelitarnego można wykrywać różne cechy gleb, które istotnie wpływają na ich jakość, co stanowi pewną przesłankę odnośnie do możliwości wydzielenia klas bonitacyjnych na podstawie danych satelitarnych.

W ostatnich latach dużo uwagi poświęcano m.in. rozpoznawaniu typów gleb (Dematté i in. 2018), zawartości poszczególnych pierwiastków (Gallo i in. 2018, Kalambukattu i in. 2018), frakcji granulometrycznej (Gallo i in. 2018, Hosseini i in. 2014), wilgotności gleby (Gruszczynska i Dąbrowska-Zielińska 2004, Hosseini i in. 2014, Bauer-Marschallinger i Paulik 2019, EU, 2020) oraz zasolenia (Kokoeva 2007). Wśród źródeł danych można wymienić dane satelitarne optyczne (Hosseini i in. 2014, Dematté i in. 2018, Gallo i in. 2018, Kalambukattu i in. 2018) oraz radarowe (Gruszczynska, Dąbrowska-Zielińska 2004, Bauer-Marschallinger i Paulik 2019). W przypadku danych optycznych zaproponowane rozwiązania korzystają raczej z analizy odkrytej gleby (Dematté i in. 2018, Gallo i in. 2018, Kalambukattu i in. 2018). Zazwyczaj stosowane są obrazy pochodzące z jednej daty (Gruszczynska i Dąbrowska-Zielińska 2004, Kalambukattu i in. 2018), lecz są także opracowania, w których wykorzystywano dane wieloletnie (Dematté i in. 2018, Gallo i in. 2018). Wciąż często używanym algorytmem do wyznaczania modeli jest regresja liniowa z wykorzystaniem autokorelacji przestrzennej (Gruszczynska, Dąbrowska-Zielińska 2004, Dematté i in. 2018, Gallo i in. 2018) oraz krieging (Hosseini i in. 2014), choć zastosowanie również znajdują różne narzędzia klasyfikacji nienadzorowanej i nienadzorowanej (Kokoeva 2007),

jak i sieci neuronowe (Gallo i in. 2018, Kalambukattu i in. 2018). Istnieje możliwość wyznaczenia gatunku gleby z dużym sukcesem na podstawie jej obrazu wielospektralnego Landsat 5 co udowodnili Demattê i in. (2018). W Kalambukattu i in. (2018) opisano z kolei próbę wyznaczenia zawartości węgla organicznego, azotu dostępnego oraz fosforu dostępnego z użyciem konwolucyjnej sieci neuronowej w odniesieniu do danych satelitarnych Landsat-8 i numerycznego modelu terenu (NMT). Okazuje się, że uzyskano modele szacowania węgla organicznego i azotu ze współczynnikami determinacji odpowiednio 83% i 62%. Model szacowania fosforu okazał się gorszy, ze współczynnikami determinacji na poziomie 51%. To badanie wskazuje jednak na duży potencjał wykorzystania sieci neuronowych do modelowania właściwości chemicznych gleby.

Tabela 1. Klasy bonitacyjne na gruntach ornych wyciąg z Załącznika do rozporządzenia Rady Ministrów z dnia 12 września 2012 r. (poz. 1246).

Tabela 1. To jest tabela. Tabele powinny być umieszczone w głównym tekście blisko miejsca, w którym są pierwszy raz cytowane.

Klasa	Nazwa klasy bonitacyjnej	Charakterystyka klasy bonitacyjnej
I	gleby orne najlepsze	Gleby te występują zawsze w dobrych warunkach fizjograficznych, tj. na równinach lub na bardzo łagodnych (do 2°) pochyłościach, są zasobne we wszystkie składniki odżywcze dla roślin, mają dobrą naturalną strukturę, nawet na znacznej głębokości, są łatwe do uprawy, ciepłe, czynne, przepuszczalne i przewiewne, ale przy tym dostatecznie wilgotne, niezaskorupiające się. Mają w dobrze wykształconym i głębokim poziomie próchnicznym słodką próchnicę niewykazującą większego zakwaszenia. Mają właściwe stosunki wodne i nie wymagają melioracji.
II	gleby orne bardzo dobre	Gleby zbliżone właściwościami do gleb klasy I, ale występują już w nieco gorszych warunkach fizjograficznych lub mają nieco gorsze właściwości fizyczne, np. są mniej przepuszczalne i mniej przewiewne oraz trudniejsze do uprawy. Gleby te są zmeliorowane lub nie wymagają melioracji.
IIIa	gleby orne dobre	Gleby te mają gorsze właściwości fizyczne lub chemiczne, lub występują w gorszych warunkach fizjograficznych niż gleby klasy I i II. Przede wszystkim odnosi się to do stosunków wodnych (poziom wód gruntowych może ulegać stosunkowo znacznym wahaniom). Gleby w tej klasie są zmeliorowane lub nie wymagają melioracji.
IIIb	gleby orne średnio dobre	Gleby te są zasadniczo zbliżone właściwościami do gleb klasy IIIa, ale mają gorsze właściwości fizyczne lub chemiczne, lub występują w gorszych warunkach fizjograficznych. Poziom wód gruntowych ulega jeszcze większym wahaniom, a plony są uzależnione w jeszcze większym stopniu od warunków atmosferycznych, niekiedy bywają to gleby okresowo za suche, inne mogą być okresowo za mokre. Gleby te mogą być również narażone na erozję.
IVa	gleby orne średniej jakości, lepsze	Gleby te nieraz występują w gorszych warunkach fizjograficznych, na większych spadkach, mogą być narażone na erozję wodną. Gleby ciężkie tej klasy są zasobne w składniki pokarmowe i charakteryzuje je duża żyzność potencjalna, ale są mało przewiewne, zimne i mało czynne, przeważnie ciężkie do uprawy, w okresach upałów zaskorupiają się, tworząc głębokie pęknięcia i szczeliny lub bryły trudne do rozbicia.
IVb	gleby orne średniej jakości, gorsze	Gleby te zasadniczo są zbliżone swymi właściwościami do gleb klasy IVa, ale są bardziej od nich wadliwe – albo zbyt suche, albo zbyt wilgotne.
V	gleby orne słabe	Gleby te są mało żyzne i mało urodzajne. Należą do nich gleby zbyt lekkie, za suche, ale zalicza się do niej również płytkie i kamieniste gleby, najczęściej ubogie w materię organiczną oraz gleby zbyt mokre, niezmeliorowane lub nienadające się do melioracji.
VI	gleby orne najslabsze	Gleby te są bardzo słabe, wadliwe, dają plony niskie i niepewne. Podmokłe gleby tej klasy wykazują stale za wysoki poziom wód gruntowych, często występuje storfiąły lub zmurszały utwór organiczny. Do klasy tej należą również gleby lekkie, za suche, ale również gleby bardzo płytkie (płytsze niż gleby należące do klasy V) lub płytkie i silnie kamieniste, przez co trudne do uprawy.
VIz	gleby orne najslabsze, trwale za suche lub za mokre gleby orne pod zalesienia	Do tej klasy zalicza się gleby suche, nieprzydatne do uprawy polowej. Wyjątkowo zalicza się do tej klasy także niektóre bardzo podmokłe piaski, nieprzydatne jako grunty orne ani łąki trwale i pastwiska trwale

Innym kierunkiem w teledetekcji gleb jest wykorzystanie danych wieloletnich. Gallo i in. (2018) podjęli się próby modelowania właściwości fizycznych i chemicznych gleb w oparciu o obrazy syntetyczne utworzone na podstawie danych wieloletnich. Jak piszą autorzy, dzięki temu wartości odbicia spektralnego gleby zostało pozbawione błędów grubych, jak również uzyskano pokrycie danymi sięgające 50%, co poprawiło jakość oraz powiększyło zestaw danych wejściowych. Modele utworzone metodą regresji liniowej i autokorelacji



przestrzennej dość dobrze wyznaczały frakcję granulometryczną (na potrzeby eksperymentu wyznaczono cztery klasy granulometryczne) z dokładnością 74%.

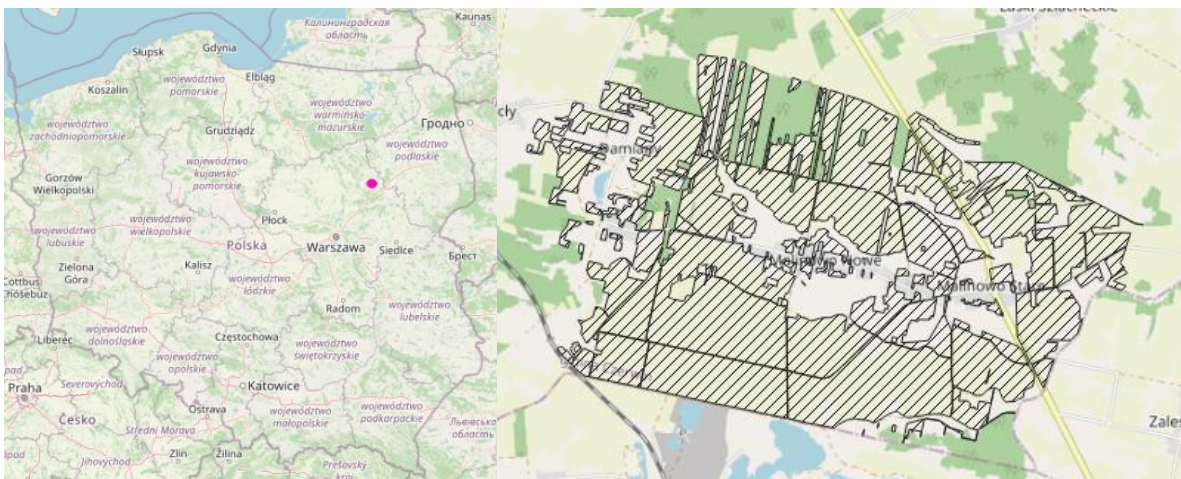
Z kolei wilgotność gleb jest możliwa do wyznaczania z dość dużą dokładnością z wykorzystaniem danych radarowych. W eksperymencie przedstawionym przez Gruszczyńską i Dąbrowską-Zielińską (2004) badano korelacje pomiędzy wilgotnością gleby a zarejestrowaną intensywnością odbicia wstecznego w zależności od fazy wegetacji roślinności i szorstkości terenu, mierzoną Leaf Area Index (LAI). Współczynniki korelacji pomiędzy odbiciem wstecznym wiązki radarowej a wilgotnością gleby miały wartości około 0,8. Na danych radarowych bazuje również produkt Surface Soil Moisture (wilgotność powierzchniowa gleby) (SSM) tworzony przez Europejską Agencję Kosmiczną (ESA) (Bauer-Marschallinger i Paulik 2019, EU 2020). Produkt ten powstał z myślą o monitorowaniu zagrożenia suszą, lecz jednocześnie wskazuje, że warunki wodne gleby są możliwe do wyznaczenia z użyciem danych teledetekcyjnych.

Przedstawione badania dotyczą obszarów wykorzystywanych intensywnie rolniczo, lecz należy zwrócić uwagę na to, że badania dotyczące cech fizycznych i chemicznych są prowadzone na obszarach tropikalnych (Brazylia (Demattê i in. 2018, Gallo i in. 2018), Indie (Kalambukattu i in. 2018)) lub pustynnych (Kirgistan (Kokoeva 2007), Iran (Hosseini i in. 2014)). Badania w strefie umiarkowanej najczęściej sprowadzają się do badania wilgotności (Europa (Gruszczyńska, Dąbrowska-Zielińska 2004, Bauer-Marschallinger i Paulik 2019, EU 2020)).

Dokonany przegląd literatury potwierdza, że parametry dotyczące żyzności gleb są możliwe do wychwycenia z pałapu satelitarnego, a uczenie maszynowe pozwoliło na automatyzację wielu procesów, również w teledetekcji (Shiqi i in. 2017, Bielecki 2018, Szkibieli 2019, Osińska-Skotak i in. 2021), w tym w teledetekcji gleb (Kalambukattu i in. 2018). Należy zauważyć, że w wyżej przedstawionych rozwiązaniach poświęcono uwagę parametrom, które składają się na określenie klasy bonitacyjnej gleby, jednak w literaturze nie znaleziono informacji o podejmowaniu prób wydzielenia konturów klas bonitacyjnych z wykorzystaniem metod sztucznej inteligencji i produktów teledetekcyjnych. W związku z tym postanowiono sprawdzić, czy jest możliwe stworzenie modelu, który by wyznaczał klasę bonitacyjną gleby z użyciem danych teledetekcyjnych oraz pochodnych numerycznego modelu terenu. Postawiono również pytania badawcze: 1. czy algorytmy uczenia maszynowego (lasy losowe oraz konwolucyjne sieci neuronowe) pozwolą na uzyskanie wysokiej (powyżej 80%) dokładności delimitacji klas bonitacyjnych? 2. czy możliwe jest uzyskanie powtarzalności działania algorytmu na danych zarejestrowanych w innym terminie? 3. Jak na skuteczność delimitacji klas bonitacyjnych wpływają parametry algorytmów uczenia maszynowego (np. liczba warstw ukrytych, liczba drzew decyzyjnych)?

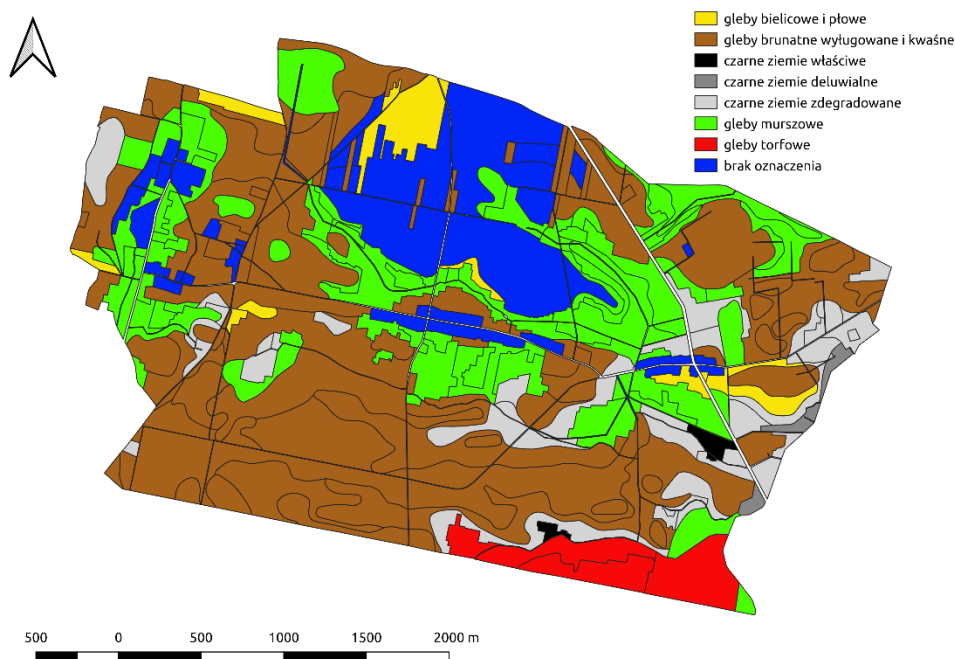
## Obszar badań

W celu przeprowadzenia badania pozyskano zestaw danych referencyjnych dla obszaru obejmującego trzy wioski w gminie Czerwin, w województwie mazowieckim w powiecie ostrołęckim: Damiany, Malinowo Stare i Nowe (Ryc. 1). Na obszarze tym występuje 7 zidentyfikowanych typów gleb (Ryc. 2), z czego udział 3 różnych (brunatnych, murszowych i czarnych ziemi zdegradowanych) można uznać za znaczący (Ryc. 4b). Poza tym występuje 6 różnych klas bonitacyjnych (ryc. 3) o oznaczeniach od IIIb do VIz, przy czym tylko udział klasy IIIb oraz VIz jest szczątkowy (Ryc. 4a). Dodatkowo na tym terenie dominują grunty orne, dla których sezonowo występuje zjawisko odkrytej gleby, co umożliwia badania teledetekcyjne gleby.



Ryc. 1. Położenie obszaru badawczego oraz zasięg terenów sklasyfikowanych jako grunty orne z wyłączeniem gruntów ornich zabudowanych.

Fig. 1. The location of the research area and the extent of land classified as arable land, excluding built-up arable land.



Ryc. 2. Mapa typów gleb dla obszaru badawczego.

Fig. 2. The location of the research area and the extent of land classified as arable land, excluding built-up arable land.

### Metodyka badań i dane źródłowe

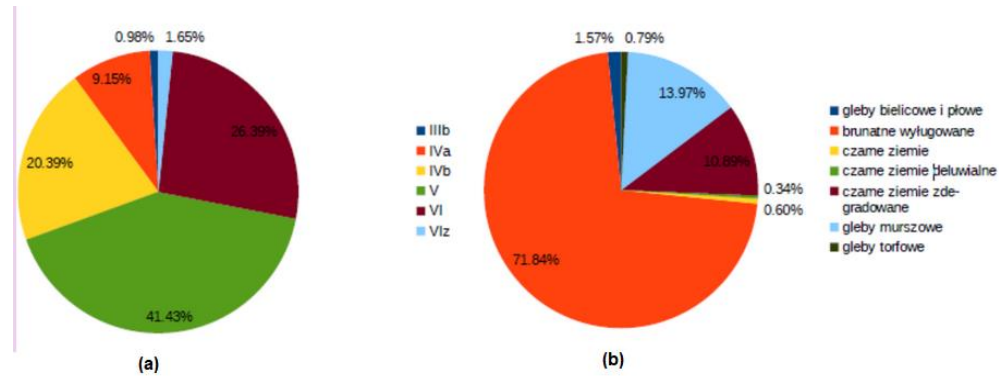
Ze względu na już podkreśloną istotną rolę klasyfikacji bonitacyjnej w polskim systemie prawnym jako cel badania postawiono sprawdzenie czy wykorzystanie algorytmów sztucznej inteligencji oraz danych teledetekcyjnych może pozwolić na stworzenie takiego rozwiązania, które z dużą skutecznością przewidywałoby klasę bonitacyjną gruntu ornego.

Wybór obszaru badawczego podyktowany był faktem dostępności rzetelnych, zweryfikowanych w terenie danych dot. cech gleb występujących na tym obszarze niezbędnych do przeprowadzenia prac eksperymentalnych.



Ryc. 3. Mapa konturów klasyfikacyjnych dla obszaru badawczego.

Fig. 3. Map of classification contours for the research area.



Ryc. 4. Udział poszczególnych klas bonitacyjnych (a) oraz typów gleb (b) na gruntach ornym obszaru badawczego.  
Fig. 4. The share of individual bonitation classes (a) and soil types (b) on arable lands of the research area.

Eksperyment badawczy podzielono na cztery etapy:

- dobór danych,
- przygotowanie danych,
- trening algorytmów oraz
- ocenę skuteczności działania,

przy czym eksperyment był realizowany w różnych scenariuszach – testowano różne metody uczenia maszynowego i ustawienia parametrów wejściowych w odniesieniu do:

- lasów losowych (ang. Random Forest, You, 2019.) (różna liczba drzew decyzyjnych) i
- sztucznych sieci neuronowych (różne modele sieci, różna liczba warstw, różna liczba neuronów).

#### Prace koncepcyjne

Na wstępie dokonano analizy cech gleb, które wpływają na zaliczenie do konkretnej klasy bonitacyjnej (Tabela 1) oraz możliwości ich określenia na podstawie danych przestrzennych, w szczególności danych teledetekcyjnych – optycznych i radarowych. Na tej podstawie dokonano wyboru danych źródłowych potrzebnych do przeprowadzenia eksperymentu badawczego. Analizując cechy kluczowe dla opisu klas bonitacyjnych gleb stwierdzono, że do opisu typu gleby, jej barwy i struktury należy wykorzystać zarówno zobrazowania optyczne, jak i radarowe. Jak wskazuje Białousz (2015) głównymi czynnikami wpływającymi na wartość odbicia spektralnego gleby rejestrowanego na obrazach satelitarnych są zgrużenie powierzchni, wilgotność i barwa, zatem czynniki powiązane wprost z typem gleby i kluczowe podczas określania klasy bonitacyjnej gleb. Jednak o odbiciu światła słonecznego decyduje wyłącznie wierzchnia warstwa gleby od kilku centymetrów dla gleb zgrużonych, do paru milimetrów w przypadku gleb o powierzchni gładkiej, co nieco ogranicza zastosowanie danych optycznych w określaniu typu gleb. Z pułapu satelitarnego niestety nie można wnioskować o budowie (profilu) gleby ani o zawartości jej podziemia. Ponadto duża część cech fizycznych i chemicznych mających wpływ na urodzajność lub trudność uprawy (plastyczność, lepkość, kurczliwość i pęcznienie, odczyn) również nie jest możliwa do wyznaczenia, choć w niektórych przypadkach są związane np. z barwą gleby (np. ponieważ węgiel wapnia jest składnikiem zasadowym, można wnioskować o odczynie gleby). Jednak nie są one na tyle kluczowe, by istotnie utrudnić zadanie klasyfikacji bonitacyjnej. Białousz (2015) wskazuje także, że większa głębokość penetracji gleby może być dostępna dla obrazowania radarowego, dzięki czemu lepiej można określić np. przepuszczalność czy wilgotność gleby.

W celu określenia położenia w terenie (w tym pochyłość terenu istotna w klasyfikacji bonitacyjnej gleb), należy wykorzystać numeryczny model terenu oraz produkty pochodne, takie jak: nachylenie terenu czy wystawa słoneczna. Warunki hydrologiczne dobrze odzwierciedlają dwa wskaźniki, które były już stosowane w teledetekcji gleb. Są to Topographic Wetness Index (TWI) i Stream Power Index (SPI) (Kalambukattu i in. 2018). W obu tych wskaźnikach istotnym elementem jest modelowanie przepływu. Zadaniem TWI jest modelowanie nawodnienia danego miejsca. Jest on wprost proporcjonalny do przepływu i odwrotnie proporcjonalny do spadku terenu i jest określony następującym wzorem:

$$TWI = \frac{\ln flow}{\tan \beta}$$

gdzie *flow* oznacza przepływ, a  $\beta$  nachylenie wyrażone w stopniach.

SPI modeluje natomiast siłę erozyjną wody, która jest wprost proporcjonalna zarówno do przepływu, jak i spadku terenu. SPI wyrażony jest następującym wzorem:



$$SPI = \ln flow \cdot \tan \beta$$

Podsumowując przeprowadzoną analizę, stwierdzono, że w celu jak najlepszego opisanie cech gleb ważnych z punktu widzenia wydzielenia klas bonitacyjnych za niezbędne do przeprowadzenia eksperymentu należy uznać zobrazowania optyczne i radarowe oraz produkty pochodne numerycznego modelu terenu, których przygotowanie szczegółowo opisano poniżej.

#### Dane źródłowe

Danymi źródłowymi do przeprowadzenia eksperymentu były dwa zestawy zobrazowań satelitarnych z konstelacji Sentinel, numeryczny model rzeźby terenu (NMT) oraz jego produkty pochodne. Zobrazowania satelitarne pozyskano z programu Copernicus, natomiast NMT pochodzi z projektu ISOK i ma rozdzielczość terenową 1m x 1 m. Zestaw danych referencyjnych stanowiły zaś warstwy tematyczne dot. użytkowania terenu, typu gleb (Ryc. 2) oraz kontury klasyfikacyjne (Ryc. 3) pochodzące z mapy glebowo-rolniczej w skali 1:5 000, zaktualizowanej przez specjalistę z zakresu gleboznawstwa.


Wśród danych satelitarnych znalazły się zobrazowanie optyczne Sentinel-2, zobrazowanie radarowe Sentinel-1, które stanowiły dwa niezależne zestawy danych (Tabela 2) - jeden jako zestaw treningowy, a drugi jako zestaw testowy. Dla celów treningowych zostały pobrane obrazy Sentinel-2 (Ryc. 5a) oraz Sentinel-1 z dnia 15.03.2020 (Ryc. 6a). Drugi zestaw danych obejmował zobrazowania optyczne Sentinel-2 zarejestrowane w dniu 19.09.2018 oraz dane radarowe Sentinel-1 pozyskane dzień później - 20.09.2020. Na obu zestawach danych satelitarnych występuje licznie odkryta gleba, co było głównym kryterium wpływającym na wybór terminów rejestracji danych satelitarnych. Przy wyborze danych zwracano również uwagę na warunki pogodowe panujące tuż przed rejestracją zobrazowań, w tym szczególnie na fakt wystąpienia opadów, co mogłoby zaburzać wyniki klasyfikacji klas bonitacyjnych.

Obrazy Sentinel-2 pobrano na poziomie przetwarzania 2A, natomiast dane z Sentinel-1 na poziomie przetwarzania 1 GRD. Są to najwyższe poziomy przetwarzania danych udostępniane przez Europejską Agencję Kosmiczną. Zobrazowania radarowe na poziomie 1 GRD są to dane korygowane na wysokość gruntu z wykorzystaniem modelu elipsoidy Ziemi i zawierają informacje o amplitudzie. Z kolei poziom 2A w odniesieniu do obrazów Sentinel-2 oznacza, że dane zostały poddane korekcjom geometrycznej i radiometrycznej, w tym uwzględniono wpływ atmosfery, a wartości pikseli przedstawiają odbicie spektralne na poziomie gruntu.

Tabela 2. Terminy rejestracji zobrazowań satelitarnych Sentinel wykorzystanych jako zestawy treningowy i testowy.


Table 2. To jest tabela. Tabele powinny być umieszczone w głównym tekście blisko miejsca, w którym są pierwszy raz cytowane.

	Sentinel-1	Sentinel-2
Zestaw treningowy	15.03.2020	15.03.2020
Zestaw testowy	19.09.2018	20.09.2018



Ryc. 5. Obszar badawczy przedstawiony na zobrazowaniach Sentinel-2 w postaci kompozycji w barwach naturalnych, a) zestaw treningowy, b) zestaw testowy.

Fig. 5. The research area presented in Sentinel-2 images in the form of compositions in natural colors, a) training set, b) test set.



Ryc. 6. Obszar badawczy przedstawiony w kompozycji, utworzonej ze zobrażeń radarowego Sentinel-1 oraz optycznego Sentinel-2: R – polaryzacja VV, G – kanał 8, B – kanał 3, a) zestaw treningowy, b) zestaw testowy.

Fig. 6. The research area presented in a composition, created from the radar imagery of Sentinel-1 and optical Sentinel-2: R - VV polarization, G - channel 8, B - channel 3, a) training set, b) test set.

#### Przygotowanie danych

Drugi etap – przygotowanie danych (Ryc. 7) – składał się z dwóch podetapów – pierwszy wykonany przy użyciu oprogramowania QGIS miał na celu stworzenie danych treningowych w postaci rastrow, a drugi wykonany programistycznie w języku Python wydobywał dane z rastrow i zapisywał je w postaci tabelarycznej.



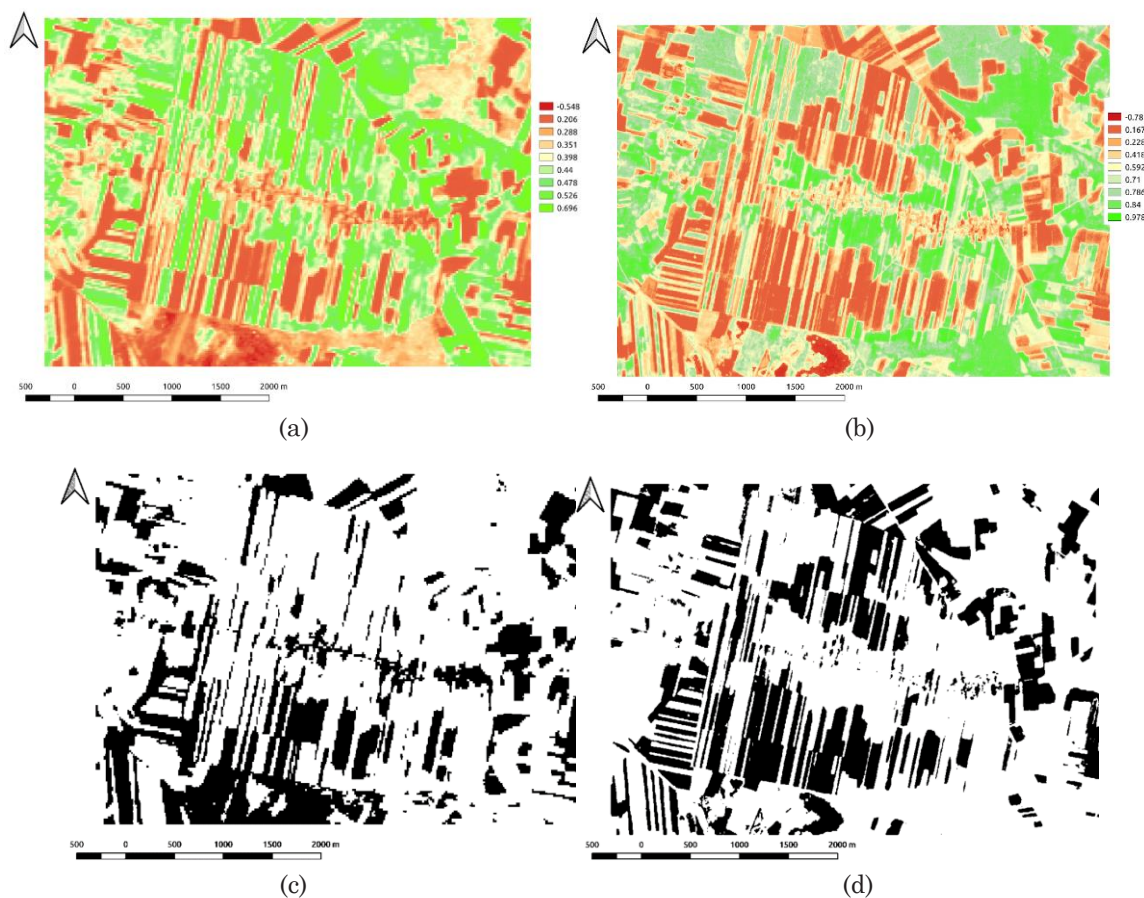
Ryc. 7. Schemat przygotowania danych i utworzenia danych treningowych.

Fig. 7. The scheme of data preparation and creation of training data.

Przygotowanie danych źródłowych i materiałów referencyjnych polegało przede wszystkim na przekonwertowaniu wszystkich danych do jednego układu współrzędnych, przycięciu danych do granic opracowania, a w przypadku arkuszy numerycznego modelu terenu połączeniu arkuszy. Wszystkie dane zostały przetransformowane do układu współrzędnych PUGW 1992 i zapisana w postaci rastrowej o rozdzielczości przestrzennej 10 m x 10 m. W przypadku konturów klasyfikacyjnych uzupełniono atrybut o etykietę klasy, a z mapy glebowo-rolniczej w postaci bazy danych przygotowano raster z typami gleb.

Ze względu na to, że do badań należało wytypować jedynie obszary gleby odkrytej, na podstawie pobranego obrazu optycznego Sentinel-2 obliczono wskaźnik roślinności NDVI (Ryc. 8a i b), który posłużył do ekstrakcji odkrytej gleby (Ryc. 8c i d) zgodnie z metodyką zaproponowaną przez Demattê i in. (2018) oraz Gallo i in. (2018). Za wartość graniczną progowania – po kilku iteracjach oceny wizualnej – uznano 0,4.

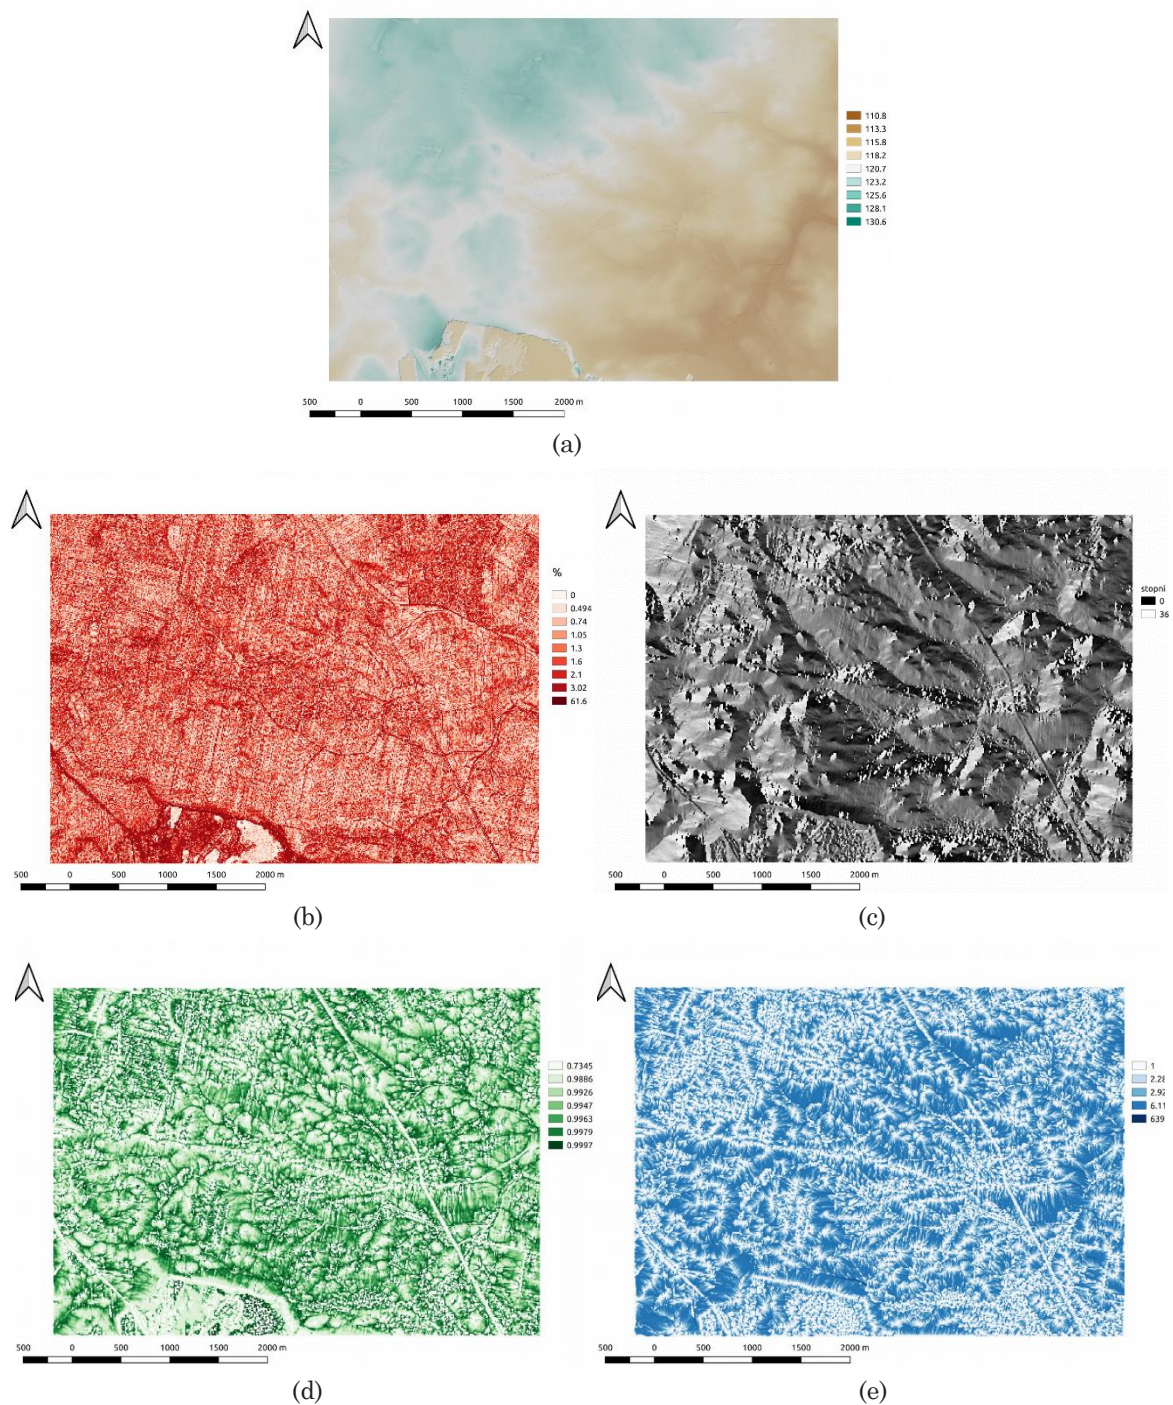




Ryc. 8. Rozkład wartości NDVI na obszarze badań dla: a) obrazu treningowego i b) obrazu testowego oraz uzyskanej maski gleb odkrytych dla: c) obrazu treningowego i b) obrazu testowego.

*Fig. 8. The distribution of NDVI values in the research area for: a) training image and b) test image, and the obtained mask of exposed soils for: c) training image and d) test image.*

Do danych uczących zostały również dołączone przetworzenia numerycznego modelu terenu (NMT): nachylenie terenu (Ryc. 9b), wystawa słoneczna (Ryc. 9c) oraz wskaźniki - Topographic Wetness Index (TWI, Ryc. 9d) oraz Stream Power Index (SPI, Ryc. 9e) odzwierciedlające odpowiednio wilgotność miejsca oraz siłę erozyjną wody.



Ryc. 8. Wizualizacja numerycznego modelu terenu (a) oraz produktów pochodnych: b) nachylenia terenu, c) wystawy słonecznej, d) topograficznego wskaźnika wilgotności TWI, e) wskaźnika siły erozyjnej wody SPI.

Fig. 8. Visualization of the digital terrain model (a) and derivative products: b) terrain slope, c) solar exposure, d) topographic wetness index TWI, e) water erosivity index SPI.

Wykaz wykorzystanych danych i produktów pochodnych został zamieszczony w Tabeli 3.

Tabela 3. Wykorzystane zestawy danych wejściowych.  
Table 3. Used input data sets.

Źródło danych	Warstwa / produkt pochodny
Sentinel-2	Kanał 2 – niebieski
	Kanał 3 – zielony
	Kanał 4 – czerwony
	Kanał 8 – bliska podczerwień
	Kanał 5 – vegetation red edge
	Kanał 6 – – vegetation red edge
	Kanał 7 – – vegetation red edge
	Kanał 8A – – vegetation red edge
	Kanał 11 – daleka podczerwień
	Kanał 12 – – daleka podczerwień
Sentinel-1	Polaryzacja VV
	Polaryzacja HV
NMT	Nachylenie
	Wystawa słoneczna
	Topographic Wetness Index -- TWI
	Stream Power Index -- SPI

#### Wybór typów gleb do klasyfikacji bonitacyjnej gleb

Zarówno dla zestawu treningowego jak i testowego wyodrębniono pojedyncze piksele zawierające odkrytą glebę na gruntach ornych wraz z podziałem na typy gleb oraz klasy bonitacyjne oraz podzielono według istotności rozkładu. Za znaczący udział uznano występowanie co najmniej 10 pikseli w przynajmniej dwóch klasach bonitacyjnych dla pojedynczego typu gleb. W Tabeli 4 ukazano zestawienie liczebności rekordów dla poszczególnych klas bonitacyjnych z oznaczeniem znaczącego udziału na zielono oraz nieznaczącego na czerwono. Jedynie dla dwóch typów gleb: gleby brunatne wylugowane i kwaśne oraz czarne ziemie zdegradowane, zaobserwowano znaczące ich występowanie zarówno dla zestawu treningowego i testowego. Dlatego dla tych dwóch klas postanowiono przeprowadzić dalsze badanie. W pozostałych klasach próbki byłyby zbyt mało liczne.

Tabela 4. Liczebność rekordów dla poszczególnych klas bonitacyjnych z podziałem na typy gleb.  
Table 4. The number of records for individual bonitation classes divided by soil types.

Typ	zestaw	klasa bonitacyjna					
		IIIb	IVa	IVb	V	VI	VIz
gleby bielcowe	trening				534	31	
	test				661	1	
gleby brunate wylugowane i kwaśne	trening		517	4760	14885	7241	200
	test			11177	7433	8418	1314
czarne ziemie	trening		32				
	test		15				
czarne ziemie deluwialne	trening		4	1			
	test						
czarne ziemie zdegradowane	trening	142	1135	1074	434	229	
	test		74	107	1570	282	
gleby murszowe	trening		80	364	2046	423	
	test			7	1806		
gleby torfowe	trening		6	119		11	
	test			53			

Dla tych dwóch typów danych wyekstrahowano z danych treningowych piksele wraz z otoczeniem w oknie 7x7 pikseli. Jeżeli okno wychodziło poza granicę rastra, brakujące wartości zastąpiono zerami. Tak przygotowany zestaw poddano dalszym etapom opracowania.



### Metody klasyfikacji

W badaniach wykorzystano algorytm lasów losowych oraz sieci neuronowe. Dla lasów losowych jedynym parametrem wejściowym jest liczba drzew decyzyjnych, toteż zbadano zachowanie się lasów o liczbie 10, 20, 50, 100 i 200 drzew. W przypadku sieci neuronowych testowano liczebność warstwy ukrytych. W przypadku sieci neuronowych zdecydowano się na trzy podstawowe modele: perceptron, konwolucyjny 5 i konwolucyjny 7. Pierwszy z nich jako dane wejściowe przyjmuje wyłącznie wartości warstw wejściowych zawartych w ramach jednego piksela. Sieci konwolucyjne rozpatrują okienka wejściowe o rozmiarze 5x5 i 7x7. Model konwolucyjny 5 zawiera 2 warstwy konwolucyjne o oknie filtra 3x3, przesunięciu 1 i bez uzupełniania zerami. Model konwolucyjny 7 obejmuje jeszcze jedną taką warstwę konwolucyjną. Modele konwolucyjne są zakończone perceptronem. Jako funkcji aktywacyjnej użyto ReLU. Modele można parametryzować poprzez liczbę warstw ukrytych i liczbę neuronów przypadających na warstwę. Dla sieci konwolucyjnych parametr liczby neuronów oznacza również głębokość warstw konwolucyjnych.

Postanowiono sprawdzić wpływ liczby warstw ukrytych w przedziale <1,4> oraz liczby neuronów w przedziale <3,9> na skuteczność wykrywania obu typów gleb. Sprawdzono każdą parę, czyli łącznie przeprowadzono 28 testów na podstawowy model sieci neuronowej. Wszystkie operacje zautomatyzowano z wykorzystaniem autorskich skryptów przygotowanych w języku Python.

### Ocena dokładności

Skuteczność przeprowadzonych klasyfikacji określono za pomocą macierzy błędów (Congalton, 1991) oraz obliczonych na jej podstawie wskaźników, w tym: precyzji (ang. precision), czułości (ang. recall) oraz współczynnika F1 (Koga, 2018). Macierz błędów jest tabelą, w której wiersze reprezentują prawdziwą odpowiedź dla danego obiektu, a kolumny wskazaną przez model. Na przekątnej macierzy znajduje się informacja o poprawnie sklasyfikowanych obiektach, a poza nią o błędach w klasyfikacji. Podstawową miarą skalarną dokładności modelu jest skuteczność, czyli stosunek sumy elementów położonych na przekątnej głównej macierzy błędów do ogólnej liczby obiektów, lecz znajduje ona zastosowanie tylko w przypadku zrównoważenia klas w zestawie walidacyjnym. W przypadku klas nieproporcjonalnie małych, np. zawierających około 1% ogółu, klasyfikator przyjmujący wartość inną niż ta klasa może osiągnąć skuteczność 99%, choć nie będzie on dobrym klasyfikatorem. Dlatego wykorzystuje się również miary precyzji i czułości, które wyznacza się indywidualnie dla każdej klasy. Precyzja jest ilorazem liczby obiektów danej klasy poprawnie sklasyfikowanych przez model i liczby wszystkich obiektów sklasyfikowanych jako dana klasa. Czułość jest natomiast ilorazem liczby obiektów danej klasy poprawnie sklasyfikowanych przez model oraz wszystkich obiektów danej klasy. Współczynnik F1 jest średnią harmoniczną precyzji i czułości (Koga, 2018) i również jest obliczany dla każdej klasy oddzielnie.

### Wyniki i dyskusja

Wyniki skuteczności działania algorytmu lasów losowych oraz sieci neuronowych w różnych scenariuszach poddano analizie porównawczej. W tym celu przygotowano macierze (Tabele 5-12) oraz rastry błędów (Ryc. 10-13). Przy rastrach błędów znajdują się legendy z etykietami w formie zapisu A/B, gdzie A jest klasą bonitacyjną przypisaną przez algorytm, a B jest rzeczywistą klasą bonitacyjną.

Dla obu badanych typów gleb najlepsze wyniki klasyfikacji w przypadku algorytmu lasów losowych uzyskano dla liczności drzew decyzyjnych wynoszącej 100. Zauważalne jest uzyskanie dość wysokich skuteczności na danych walidacyjnych (73,67% dla gleb brunatnych i 78,19% dla czarnych ziem zdegradowanych) (Tabele 5 i 6) i niskich (18,44% dla gleb brunatnych i 9,53% dla czarnych ziem zdegradowanych) na danych testowych (Tabele 7 i 8). Widoczne jest także zróżnicowanie parametrów dokładnościowych w zależności od klasy bonitacyjnej, do której zaliczono glebę. Dla gleb brunatnych klasyfikacja nie jest zbyt udana nawet na danych walidacyjnych (Tabela 5). Tylko w dwóch klasach (V i VI) czułość była wyższa od 60%, co oznacza, że tylko one zostały rozróżnione. Bardziej udana jest klasyfikacja dla czarnych ziem zdegradowanych (Tabela 7), gdzie średnia wartość współczynników F1 wyniosła 75,19% i niewiele odbiega od skuteczności ogółem. Klasyfikacje na danych testowych należałoby zatem uznać za przypadkowe, gdyż ze wszystkich miar czułości i precyzji dla obu typów gleb tylko jedna wartość była większa od 50% (Tabele 6, 8) i dotyczą one klas, które w zestawie testowym najczęściej występują. Wskazuje to na brak powtarzalności działania algorytmu na danych zarejestrowanych w innym terminie.

Tabela 5. Macierz błędów dla lasu losowego o 100 drzewach klasyfikującego gleby brunatne dla zestawu walidacyjnego.  
 Table 5. Error matrix for the random forest with 100 trees classifying brown soils for the validation set.

		odpowiedzi						czułość	F1
		IIIb	IVa	IVb	V	VI	VIz		
e t y k i e t y	IIIb	0	0	0	0	1	0	0.00	0.00
	IVa	0	68	36	146	83	0	20.42	33.58
	IVb	0	4	1068	1116	133	0	46.01	58.81
	V	0	0	153	4785	290	0	91.53	79.30
	VI	0	0	52	765	2193	0	72.86	75.52
	VIz	0	0	2	28	98	21	14.09	24.71
precyzja		-	94.44	81.46	69.96	78.38	100.0		
								<b>skuteczność</b>	<b>73.67</b>
								<b>średnia F1</b>	<b>45.32</b>

Tabela 6. Macierz błędów dla lasu losowego o 100 drzewach klasyfikującego gleby brunatne dla zestawu testowego.  
 Table 6. Error matrix for the random forest with 100 trees classifying brown soils for the test set.

		odpowiedzi						czułość	F1
		IIIb	IVa	IVb	V	VI	VIz		
e t y k i e t y	IIIb	0	0	0	0	0	0	-	0.00
	IVa	0	0	206	141	98	0	0.00	0.00
	IVb	2	0	3079	397	1525	102	60.31	28.89
	V	2	0	6913	1049	4524	777	7.91	12.55
	VI	2	1	5381	1745	1072	419	12.44	13.43
	VIz	0	0	542	124	126	25	3.06	2.34
precyzja		0.00	0.00	18.99	30.35	14.59	1.89		
								<b>skuteczność</b>	<b>18.44</b>
								<b>średnia F1</b>	<b>9.53</b>

Tabela 7. Macierz błędów dla lasu losowego o 100 drzewach klasyfikującego czarne ziemie zdegradowane dla zestawu walidacyjnego.

Table 7. Error matrix for the random forest with 100 trees classifying degraded black soils for the validation set.

		odpowiedzi						czułość	F1
		IIIb	IVa	IVb	V	VI	VIz		
e t y k i e t y	IIIb	34	28	6	1	0	0	49.28	60.18
	IVa	5	355	44	4	9	0	85.13	78.89
	IVb	5	82	349	10	0	0	78.25	79.50
	V	0	11	28	133	11	0	72.68	78.70
	VI	0	7	5	7	72	0	79.12	78.69
	VIz	0	0	0	0	0	0	-	-
precyzja		77.27	73.5	80.79	85.81	78.26	-		
								<b>skuteczność</b>	<b>78.19</b>
								<b>średnia F1</b>	<b>75.19</b>

Tabela 8. Macierz błędów dla lasu losowego o 100 drzewach klasyfikującego czarne ziemie zdegradowane dla zestawu testowego.

Table 8. Error matrix for the random forest with 100 trees classifying degraded black soils for the test set.

		odpowiedzi						czułość	F1
		IIIb	IVa	IVb	V	VI	VIz		
e t y k i e t y	IIIb	0	16	12	108	6	0	0.00	0.00
	IVa	0	52	21	761	34	0	5.99	10.56
	IVb	0	48	25	631	16	0	3.47	6.40
	V	0	1	3	109	2	0	94.78	11.41
	VI	0	0	0	187	1	0	0.53	0.81
	VIz	0	0	0	0	0	0	-	-
precyzja		-	44.44	40.98	6.07	1.60	-		
								<b>skuteczność</b>	<b>9.20</b>
								<b>średnia F1</b>	<b>5.84</b>

Analizując macierze błędów w przypadku sieci neuronowych można stwierdzić, że najlepsze wyniki uzyskano dla modelu konwolucyjnego 5 (zawierającego 2 warstwy konwolucyjne o oknie filtra 3x3, przesunięciu 1) o czterech dodatkowych warstwach ukrytych. Dla gleb brunatnych było 8 neuronów przypadających na warstwę, a dla czarnych ziem zdegradowanych 4.

W odniesieniu do gleb brunatnych sieć neuronowa zidentyfikowała tylko klasy V i VI (Tabele 9 i 10). Zauważalne jest zachowanie skuteczności ogółem na poziomie ok. 50% dla danych testowych, lecz miara F1 jest znacznie niższa (spadek z 19% do 13%). Z analizy rastrów błędów (Ryc. 10 i 11) wynika, że w zestawie testowym znacznie więcej terenów zostało przypisane klasie V. Raster błędów dla zestawu testowego (Ryc. 11) ujawnia, że piksele sklasyfikowane jako klasa VI układają się w struktury liniowe równoległe, co oznacza, że algorytm w rzeczywistości wykrywał cechy związane z granicami działek, lub też wykrywał piksele graniczne zawierające wartość uśrednioną pomiędzy różnymi klasami pokrycia, np. roślinnością i odkrytą glebą. To może być spowodowane faktem niewystarczającej rozdzielczości przestrzennej obrazów satelitarnych Sentinel-2 i Sentinel-1 w porównaniu do dokładności delimitacji klas bonitacyjnych na mapie glebowo-rolniczej.

Czarne ziemie zdegradowane również przez sieć neuronową zostały podzielone na dwie klasy (IVa i IVb). Uzyskana skuteczność jest mniejsza niż ta otrzymana dla gleb brunatnych (37,41% na danych walidacyjnych) (Tabela 11), ale skuteczność i F1 dla zestawu testowego są wyższe (Tabele 12). Analiza rastrów błędów dla obu zestawów danych (Ryc. 12 i 13) wskazuje, że zachowana jest klasyfikacja poszczególnych klas bonitacyjnych na tych samych obszarach. Wskazuje to na powtarzalność modelu. Nie zmienia to jednak faktu, że klasyfikacja nie jest zadowalająca i nie można jej uznać za dobrą.

Tabela 9. Macierz błędów dla sieci konwolucyjnej klasyfikującej gleby brunatne dla zestawu walidacyjnego.

Table 9. Error matrix for the convolutional network classifying brown soils for the validation set.

		odpowiedzi						czułość	F1
		IIIb	IVa	IVb	V	VI	VIz		
e t y k i e t y	IIIb	0	0	0	27	11	0	0.00	0.00
	IVa	0	0	0	2056	703	0	0.00	0.00
	IVb	0	0	0	17235	1450	0	0.00	0.00
	V	0	0	0	38309	3612	0	91.38	66.64
	VI	0	0	0	15056	8710	0	36.65	44.61
	VIz	0	0	0	361	800	0	0.00	0.00
precyzja		-	-	-	52.45	56.98	-		
								<b>skuteczność</b>	<b>53.23</b>
								<b>średnia F1</b>	<b>18.54</b>



Tabela 10. Macierz błędów dla sieci konwolucyjnej klasyfikującej gleby brunatne dla zestawu testowego.  
 Table 10. Error matrix for the convolutional network classifying brown soils for the test set.

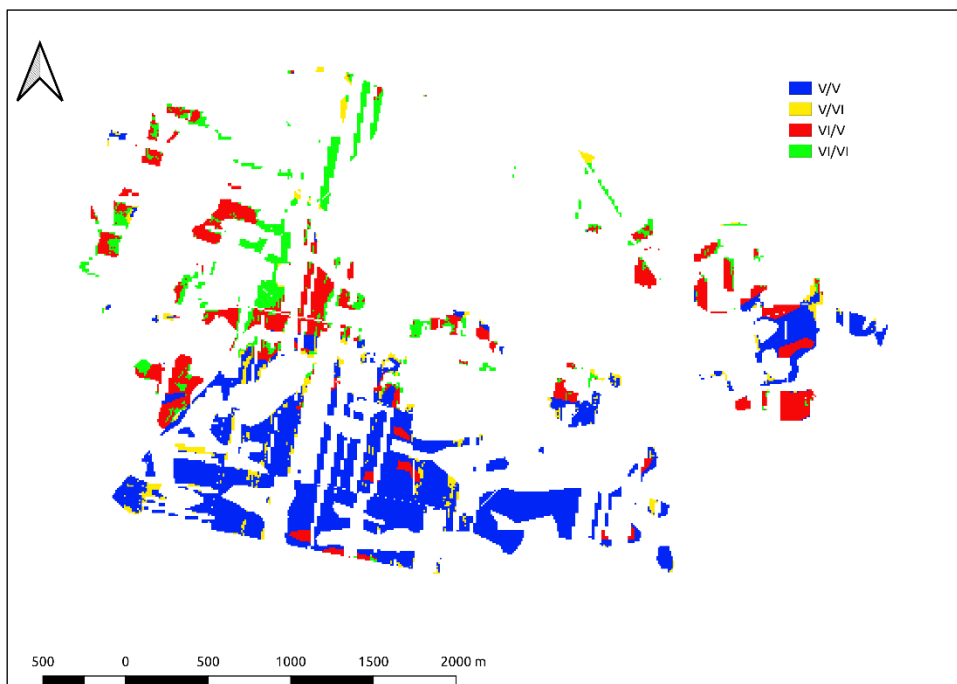
		odpowiedzi						czułość	F1
		IIIb	IVa	IVb	V	VI	VIz		
e t y k i e t y	IIIb	0	0	0	6	0	0	0.00	0.00
	IVa	0	0	0	520	15	0	0.00	0.00
	IVb	0	0	0	4783	320	0	0.00	0.00
	V	0	0	0	12450	813	0	93.87	63.06
	VI	0	0	1	7825	792	0	9.19	14.75
	VIz	0	0	0	637	180	0	0.00	0.00
precyzja		-	-	0.00	47.48	37.36	-		
								<b>skuteczność</b>	<b>46.72</b>
								<b>średnia F1</b>	<b>12.97</b>

Tabela 11. Macierz błędów dla sieci konwolucyjnej klasyfikującej czarne ziemie zdegradowane dla zestawu walidacyjnego.  
 Table 11. Error matrix for the convolutional network classifying degraded black soils for the validation set.

		odpowiedzi						czułość	F1
		IIIb	IVa	IVb	V	VI	VIz		
e t y k i e t y	IIIb	0	474	70	0	0	2	0.00	0.00
	IVa	0	2863	631	0	0	10	81.71	50.94
	IVb	0	2630	745	0	0	8	22.02	28.29
	V	0	1088	312	0	0	4	0.00	0.00
	VI	0	682	126	0	0	0	0.00	0.00
	VIz	0	0	0	0	0	0	-	-
precyzja		-	37.00	39.54	-	-	0.00		
								<b>skuteczność</b>	<b>37.41</b>
								<b>średnia F1</b>	<b>15.85</b>


Tabela 12. Macierz błędów dla sieci konwolucyjnej klasyfikującej czarne ziemie zdegradowane dla zestawu testowego.  
 Table 12. Error matrix for the convolutional network classifying degraded black soils for the test set.

		odpowiedzi						czułość	F1
		IIIb	IVa	IVb	V	VI	VIz		
e t y k i e t y	IIIb	0	107	35	0	0	0	0.00	-
	IVa	0	769	99	0	0	0	88.59	59.00
	IVb	0	599	121	0	0	0	16.81	23.87
	V	0	104	11	0	0	0	0.00	-
	VI	0	160	28	0	0	0	0.00	-
	VIz	0	0	0	0	0	0	-	-
precyzja		-	44.22	41.16	-	-	-		
								<b>skuteczność</b>	<b>43.78</b>
								<b>średnia F1</b>	<b>16.57</b>



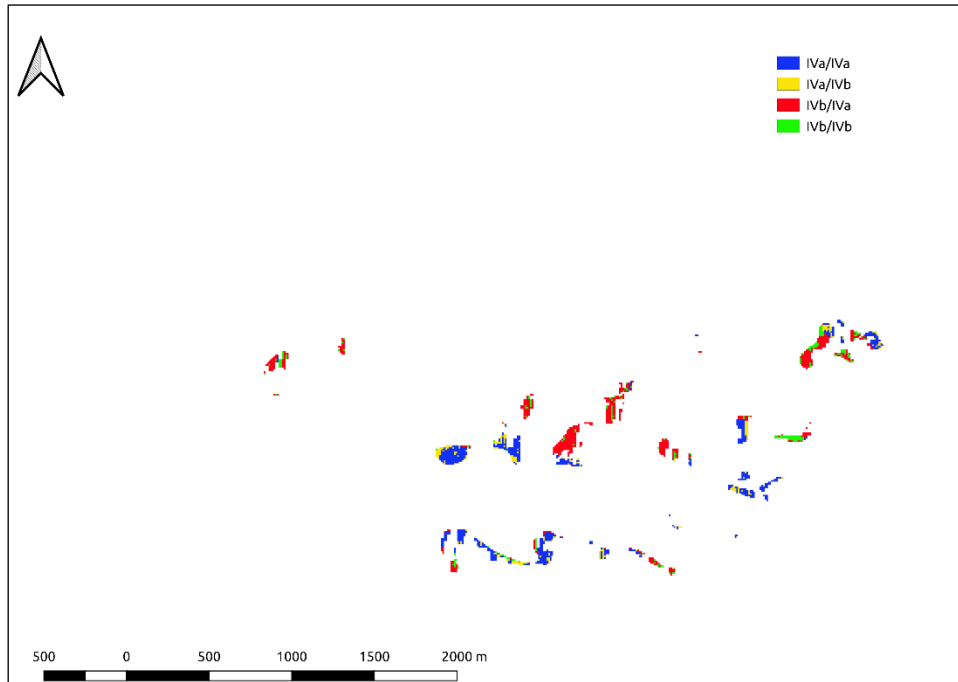
Ryc. 10. Raster błędów dla gleb brunatnych dla zestawu treningowego (oznaczenie w legendzie A/B oznacza, że A jest klasą bonitacyjną przypisaną przez algorytm, a B jest rzeczywistą klasą bonitacyjną).

*Fig. 10. Error raster for brown soils for the training set (the A/B designation in the legend means that A is the bonitation class assigned by the algorithm, and B is the actual bonitation class).*



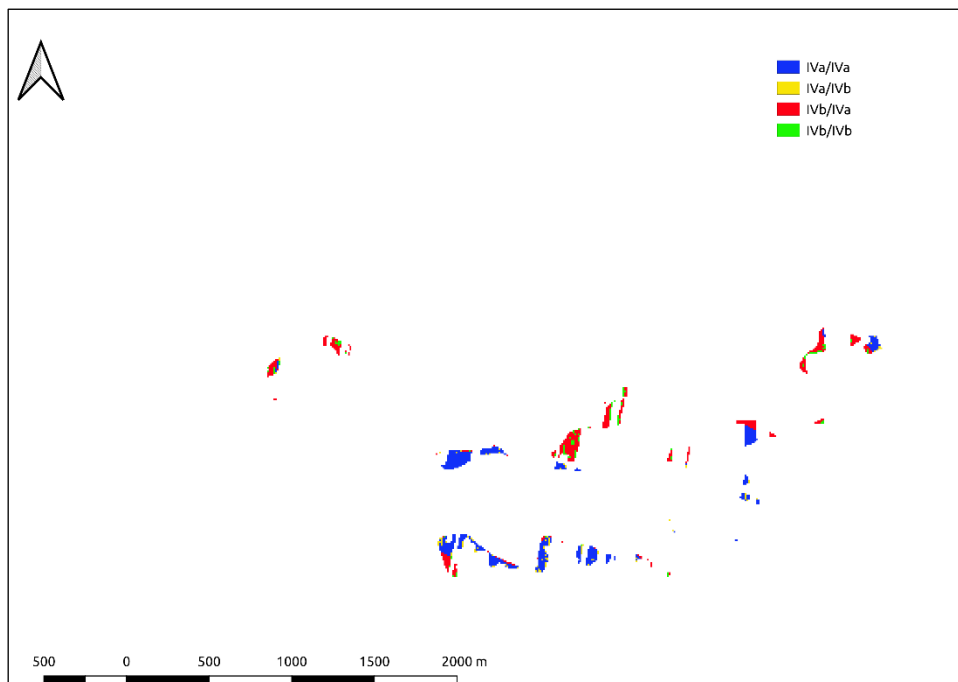
Ryc. 11. Raster błędów dla gleb brunatnych dla zestawu testowego (oznaczenie w legendzie A/B oznacza, że A jest klasą bonitacyjną przypisaną przez algorytm, a B jest rzeczywistą klasą bonitacyjną).

*Fig. 11. Error raster for brown soils for the test set (the A/B designation in the legend means that A is the bonitation class assigned by the algorithm, and B is the actual bonitation class).*



Ryc. 12. Raster błędów dla gleb czarnych ziem zdegradowanych dla zestawu treningowego (oznaczenie w legendzie A/B oznacza, że A jest klasą bonitacyjną przypisaną przez algorytm, a B jest rzeczywistą klasą bonitacyjną).

*Fig. 12. Error raster for degraded black soils for the training set (the A/B designation in the legend means that A is the bonitation class assigned by the algorithm, and B is the actual bonitation class).*



Ryc. 13. Raster błędów dla gleb czarnych ziem zdegradowanych dla zestawu treningowego (oznaczenie w legendzie A/B oznacza, że A jest klasą bonitacyjną przypisaną przez algorytm, a B jest rzeczywistą klasą bonitacyjną).

*Fig. 13. Error raster for degraded black soils for the training set (the A/B designation in the legend means that A is the bonitation class assigned by the algorithm, and B is the actual bonitation class).*

## Podsumowanie

Celem badań była analiza możliwości wykonania automatycznej gleboznawczej klasyfikacji gruntów ornych z użyciem algorytmów uczenia maszynowego z wykorzystaniem danych satelitarnych. Niestety nie uzyskano rozwiązania, które wykonało przedstawione zadanie z wysoką skutecznością i byłoby powtarzalne, na co mogło się złożyć kilka czynników, w tym:

- zbyt mały rozmiar obszaru treningowego,



- nieuwzględnienie danych wieloczasowych na etapie trenowania modeli,
- niekorzystny dobór danych satelitarnych (np. zbyt niska rozdzielczość przestrzenna, różnice w warunkach pogodowych w dłuższym okresie przed rejestracją danych satelitarnych wpływające np. na suszę glebową lub nadmierną wilgotność gleb).

Wskazane przyczyny nie wykluczają jednak możliwości uzyskania skutecznie działającego rozwiązania. Analiza badań z zakresu teledetekcji gleb wskazuje, że cechy związane z żyznością są wykrywalne z pułapu satelitarnego. W poszukiwaniu takiego rozwiązania należałoby przeprowadzić szereg dodatkowych, szeroko zakrojonych testów. Najtrudniejszym elementem, który może wpłynąć na zwiększenie szansy uzyskania skutecznego rozwiązania jest rozmiar obszaru treningowego, gdyż rozwiązanie problemu wymagałoby udostępnienia ogromnych zbiorów danych przestrzennych. Dopiero po kilku – kilkunastu kolejnych próbach będzie można stwierdzić, czy rzeczywiście można wyznaczać kontury klas bonitacyjnych przy użyciu danych satelitarnych. Jednak uzyskanie rozwiązania, które mogłoby być na tyle dobre, by dorównywało skutecznością pomiarom naziemnym jest mało prawdopodobne. Jednak tego rodzaju rozwiązanie mogłoby stanowić wsparcie podczas wyznaczania granic konturów klas bonitacyjnych. Dużym problemem – w kontekście możliwości wykorzystania danych satelitarnych – jest to, że powierzchnia odkrytej gleby na gruntach rolnych w Polsce w przeważającej części roku jest dość niewielka. Ze względu na utrzymywanie gruntów w dobrej kulturze rolnej, działania przeciwerozyjne i środowiskowe, na gruntach ornych utrzymywana jest pokrywa roślinna, co ogranicza możliwość zgromadzenia dużego zestawu danych treningowych. Wymagałoby to przygotowania danych wieloczasowych z bardzo dużego obszaru. Ponadto do oceny skuteczności algorytmów klasyfikacyjnych niezbędne jest pozyskanie danych referencyjnych w postaci baz danych o glebach zawierających zweryfikowane dane nt. typów gleb i klas bonitacyjnych gleb. Jest to zadanie trudne, ponieważ aktualizacja map glebowo-rolniczych w skali 1:5 000 dla obszaru całego kraju nie jest pełna, a bez wiarygodnych danych nie ma możliwości dokonania z jednej strony przeprowadzenia procesu uczenia algorytmu, a z drugiej oceny skuteczności jego działania.

## Bibliografia

- Bauer-Marschallinger B., Paulik C., Product User Manual, Surface Soil Moisture Collection 1km, Version 1, Dokument ESA, 2019.
- Białousz S., Podstawy fizyczne teledetekcji, 2015.
- Bielecki M., 2018. Wykrywanie wybranych klas obiektów na danych lotniczych z wykorzystaniem konwolucyjnych sieci neuronowych, Politechnika Warszawska, Wydział Geodezji i Kartografii, Warszawa 2018.
- Congalton R., 1991. A Review of Assessing the Accuracy of Classifications of Remotely Sensed Data. *Remote Sensing of Environment*, 37, pp. 35–46.
- Dematté J. A. M., Fongaro C. T., Rizzo R., Safanelli J. L., 2018. Geospatial Soil Sensing System (GEOS3): A powerful data mining procedure to retrieve soil spectral reflectance from satellite images, *Remote Sensing of Environment* 212.
- Gallo B. C. i in. 2018. Multi-Temporal Satellite Images on Topsoil Attribute Quantification and the Relationship with Soil Classes and Geology, *Remote Sensing*,
- Gruszczyńska M., Dąbrowska-Zielińska K., 2004. Szacowanie wilgotności gleb ze zdjęć mikrofalowych ERS-2, *Teledetekcja Środowiska* 33.
- Hosseini S. Z., Kappas M., Bodaghabadi M. B., Chahouki M. A. Z., Khojasteh E. R., 2014. Comparison of Different Geostatistical Methods for Soil Mapping Using Remote Sensing and Environmental Variables in Poshtkouh Rangelands, Iran, *Polish Journal Studies*, 23(3).
- Kalambukattu J. G., Kumar S., Raj A., 2018. Digital soil mapping in a Himalayan watershed using remote sensing and terrain parameters employing artificial neural network model, *Environmental Earth Science* 77.
- Koga Y., Miyazaki H., Shibasaki R., 2018. A CNN-based Method of vehicle detection from aerial images using hard example mining. *Remote Sensing*, 10(1), 124.
- Kokoeva G., 2007. Klasyfikacja gleb słonych doliny Czuj w Kirgistanie na podstawie wielospektralnych obrazów satelitarnych Landsat TM, Landsat ETM+, TERRA ASTER oraz danych naziemnych, *Teledetekcja Środowiska* 37.
- Mocek A., *Gleboznawstwo, Wydawnictwo: PWN*, 2015.
- Osińska-Skotak K., Radecka A., Ostrowski W., Michalska-Hejduk D., Charyton J., Bakula K., Piórkowski H., 2021. The Methodology for Identifying Secondary Succession in Non-Forest Natura 2000 Habitats Using Multi-Source Airborne Remote Sensing Data. *Remote Sensing* 13, 2803. <https://doi.org/10.3390/rs13142803>.
- Polskie Towarzystwo Gleboznawcze, 2008. Klasyfikacja Uziarnienia Gleb i Utworów Mineralnych.
- Rozporządzenie Ministra Rozwoju Regionalnego i Budownictwa z dnia 29 marca 2001 r. w sprawie ewidencji gruntów i budynków, Dz. U. 2019, poz. 393.
- Rozporządzenie Rady Ministrów z dnia 12 września 2012 r. w sprawie gleboznawczej klasyfikacji gruntów, Dz. U. 2012, poz. 1246.
- Shiqi Y., Jia S., Xu C., 2017. Convolutional neural networks for hyperspectral image classification, *Neurocomputing* 219.
- Szkibieli M., 2019. Opracowanie algorytmu automatycznego wykrywania zasięgów wód powierzchniowych na obrazach satelitarnych Sentinel-2, Politechnika Warszawska, Wydział Geodezji i Kartografii, Warszawa 2019.

EU, 2020. Portal Land programu Copernicus Europejskiej Agencji Kosmicznej; <https://land.copernicus.eu> (dostęp: 15.01.2020).

Yiu T., 2019. Understanding Random Forest, Towards Data Science.