



AKADEMIA GÓRNICZO-HUTNICZA IM. STANISŁAWA STASZICA W KRAKOWIE

Dyscyplina wiodąca: Nauki fizyczne
Dyscyplina dodatkowa: Nauki o Ziemi i środowisku

ROZPRAWA DOKTORSKA

Nowe metody wspomaganie obserwacji
hydrologicznych wykorzystujące
bezzałogowe statki powietrzne i uczenie
maszynowe

mgr. inż. Radosław Szostak

Promotor: dr hab. inż. Przemysław Wachniew, prof. AGH
Promotor pomocniczy: dr hab. inż. Mirosław Zimnoch, prof. AGH

Praca wykonana: Akademia Górniczo-Hutnicza im. Stanisława Staszica w Krakowie,
Wydział Fizyki i Informatyki Stosowanej, Katedra Zastosowań Fizyki Jądrowej

Kraków, 2024

Oświadczenie autora rozprawy:

Oświadczam, świadomy odpowiedzialności karnej za poświadczenie nieprawdy, że niniejszą pracę doktorską wykonałem osobiście i samodzielnie i nie korzystałem ze źródeł innych niż wymienione w pracy.

data, podpis autora

Oświadczenie promotorów rozprawy:

Niniejsza rozprawa jest gotowa do oceny przez recenzentów.

data, podpis promotora rozprawy

data, podpis promotora pomocniczego rozprawy

Badania opisane w rozprawie były wspierane w postaci:

- finansowania przez Narodowe Centrum Nauki, projekt WATERLINE (2020/02/Y/ST10/00065) w ramach programu CHISTERA IV, EU Horizon 2020 (numer grantu 857925),
- finansowania przez Akademię Górniczo-Hutniczą w Krakowie w ramach programu “Inicjatywa Doskonałości – Uczelnia Badawcza”,
- udostępnienia zasobów obliczeniowych przez infrastrukturę PLGrid.

Podziękowania

Dziękuję mojemu promotorowi **prof. Przemysławowi Wachniewowi** za codzienną gotowość pomocy, wsparcie mentorskie z zakresu hydrologii, praktyczną pomoc podczas licznych kampanii pomiarowych i inspirujące rozmowy.

Dziękuję mojemu promotorowi **prof. Mirosławowi Zimnochowi** za codzienną gotowość pomocy, wsparcie mentorskie z zakresu fizyki atmosfery, praktyczną pomoc podczas licznych kampanii pomiarowych i naukę sztuki latania bezzałogowym statkiem powietrznym.

Dziękuję **dr. Alinie Jasek-Kamińskiej** za pomoc w opracowaniu danych kowariancji wirów.

Dziękuję **prof. Pawłowi Ćwiąkale** za dzielenie się swoim doświadczeniem w dziedzinie fotogrametrii oraz praktyczną pomoc podczas kampanii pomiarowych.

Dziękuję **dr. Marcinowi Pietroniowi** za konsultacje z zakresu uczenia maszynowego.

Dziękuję **Pawłowi Jagodzie, Aleksandrze Figurze-Jagoda, dr. Alicji Skibie** i **dr. Łukaszowi Chmurze** za praktyczną pomoc podczas kampanii pomiarowych.

Spis treści

Streszczenie.....	7
Abstract	9
1. Wstęp.....	11
1.1. Motywacja.....	11
1.2. Cele pracy i hipotezy badawcze	11
1.3. Struktura rozprawy	16
2. Bieżące osiągnięcia i wyzwania metod pomiarowych w hydrologii	18
2.1. Klimatyczne i społeczne wyzwania hydrologii.....	18
2.2. Wyzwania metod pomiarowych w hydrologii	20
2.3. Bezzałogowe statki powietrzne w hydrologii	21
2.4. Pomiar poziomu powierzchni małych rzek przy pomocy BSP.....	22
2.4.1. Metody pomiaru poziomu powierzchni małych rzek przy pomocy BSP.....	22
2.4.2. Problem odwzorowania powierzchni wody na fotogrametrycznym NMPT.....	25
2.5. Termografia BSP.....	26
2.5.1. Fizyczne podstawy termografii	26
2.5.2. Problemy niechłodzonych kamer termowizyjnych	28
2.6. Ewapotranspiracja	30
2.6.1. Procesy ewapotranspiracji i jej czynniki determinujące	30
2.6.2. Pomiar ewapotranspiracji	32
2.6.3. Teledetekcyjne szacowanie ewapotranspiracji.....	33
2.6.4. Model Priestley-Taylor Jet Propulsion Laboratory (PT-JPL)	35
2.7. Uczenie maszynowe w hydrologii	36
2.7.1. Popularne zastosowania uczenia maszynowego w hydrologii.....	36
2.7.2. Przetwarzanie obrazów uczeniem maszynowym.....	37
3. Proponowane autorskie metody	39
3.1. Szacowanie poziomu wody małych strumieni przy pomocy fotogrametrii BSP i uczenia głębokiego.....	39
3.2. Automatyczna kalibracja lotniczych obrazów termowizyjnych przy użyciu optymalizacji metodą gradientów	50
3.3. Szacowanie ewapotranspiracji na podstawie termografii BSP	59
4. Dyskusja wyników	67
4.1. Wyniki szacowania poziomu wody małych strumieni przy pomocy fotogrametrii BSP i uczenia głębokiego.....	67

4.2. Wyniki automatycznej kalibracji lotniczych obrazów termowizyjnych przy użyciu optymalizacji metodą gradientów	85
4.3. Wyniki szacowania ewapotranspiracji na podstawie termografii BSP	95
5. Podsumowanie	104
Indeks skrótów	108
Bibliografia.....	109

Streszczenie

Współczesne badania hydrologiczne stają przed licznymi wyzwaniami społecznymi, klimatycznymi, technologicznymi i analitycznymi. Celem działań opisanych w niniejszej rozprawie było opracowanie nowych metod wspierających obserwacje hydrologiczne z wykorzystaniem bezzałogowych statków powietrznych (BSP) oraz technik uczenia maszynowego, dążąc do wprowadzenia innowacyjnych rozwiązań w tej dziedzinie. W ramach pracy doktorskiej opracowano trzy metody.

Pierwsza metoda dotyczy rozwiązania problemu zaburzeń w numerycznych modelach pokrycia terenu w małych strumieniach. Zastosowano sztuczną inteligencję do interpretacji zaburzeń i oszacowania poziomu wody na podstawie danych fotogrametrycznych. W tym celu użyto splotowej sieci neuronowej trenowanej metodą nadzorowaną. Przetestowano dwa warianty modelu: pierwszy, prosty, wykorzystujący enkoder do przekształcenia obrazu w pojedynczą wartość poziomu wody oraz bardziej złożoną metodę przewidującą maskę wag, którą następnie stosowano do próbkowania numerycznego modelu pokrycia terenu, co przyczyniło się do zwiększenia dokładności i wyjaśnialności rozwiązania. W tym drugim podejściu zastosowano autorską funkcję straty, pozwalającą na trening sieci neuronowej bez wzorcowych masek wag. Dane treningowe pochodziły z pięciu studiów przypadków, a do ewaluacji rozwiązania użyto dwóch metod walidacji krzyżowej. Jedną z nich była metoda all-in-case-out, pozwalająca na zbadanie skuteczności modelu na podzbiorze danych pochodzących ze studium przypadku, z którego dane nie były używane do treningu, co potwierdziło zdolność modelu do generalizacji. W zależności od studium przypadku i poziomu surowości walidacji, proponowane rozwiązanie osiągnęło błąd średniokwadratowy (RMSE) w zakresie od 2 cm do 16 cm. Metoda ta przewyższa tradycyjne podejścia oparte na prostym próbkowaniu fotogrametrycznych NMPT, osiągając średnio o 62% niższy RMSE dla rygorystycznej walidacji all-in-case-out. Wykorzystując dane z innych badań, porównano proponowane rozwiązanie na tym samym studium przypadku z innymi metodami opartymi na BSP. Osiągnęło ono dokładność porównywalną z metodą radarową, uznawaną za najdokładniejszą dostępną metodę pomiaru poziomu wody w małych rzekach z wykorzystaniem BSP.

Druga metoda dotyczyła problemu niskiej dokładności pomiaru temperatury za pomocą kamer termowizyjnych zamontowanych na BSP. Ograniczenia związane z maksymalnym udźwigniem BSP wymuszają stosowanie lekkich, niechłodzonych kamer termalnych, których wewnętrzne komponenty nie są stabilizowane temperaturowo. Powoduje to wzrost błędu pomiaru temperatury z $\pm 0,5$ °C w warunkach laboratoryjnych do ± 5 °C w niestabilnych

warunkach lotu. W rozprawie opisano procedurę przetwarzania danych, która minimalizuje te niepożądane efekty. Składa się ona z następujących etapów: (i) usunięcie winietowania za pomocą algorytmu korekcji winiety z pojedynczego obrazu, (ii) georeferencjonowanie przy użyciu metadanych obrazu oraz optymalizacji metodą gradientową, oraz (iii) optymalizacja spójności temperatury między nakładającymi się obrazami termalnymi z użyciem optymalizacji gradientowej. Rozwiązanie przetestowano na kilku obszarach rzecznych, gdzie naturalne zbiorniki wodne były używane jako punkt odniesienia dla temperatury. W testach proponowana metoda znacząco zwiększyła precyzję pomiarów. Średni błąd kwadratowy (RMSE) zmniejszył się średnio o 39%, a średni błąd bezwzględny (MAE) o 40,5%. Proponowany algorytm można określić jako samokalibrujący, ponieważ działa w pełni automatycznie, wykorzystuje jedynie dane terenowe pochodzące ze standardowego nalotu i nie wymaga dodatkowego sprzętu kalibracyjnego ani manualnej ingerencji operatora.

Trzeci projekt dotyczył adaptacji algorytmu Priestley-Taylor Jet Propulsion Laboratory (PT-JPL), pierwotnie opracowanego do szacowania ewapotranspiracji na podstawie danych z satelitarnej misji ECOSTRESS, do obliczeń ewapotranspiracji na podstawie danych zebranych za pomocą BSP. Przeprowadzono dwudniowe pomiary, podczas których zbierano dane zarówno z BSP, jak i ze stacji meteorologicznej. Dane te wykorzystano do obliczenia ewapotranspiracji za pomocą zaadaptowanego algorytmu PT-JPL oraz metody kowariancji wirów, która posłużyła jako pomiar referencyjny. Wyniki pokazały wysoką zgodność z pomiarami referencyjnymi, co wstępnie potwierdziło, że algorytm PT-JPL może być stosowany do pomiarów realizowanych za pomocą BSP.

Abstract

Contemporary hydrological research faces numerous social, climatic, technological, and analytical challenges. The aim of the activities described in this dissertation was to develop new methods supporting hydrological observations using unmanned aerial vehicles (UAVs) and machine learning techniques, with the goal of introducing innovative solutions in this field. Three methods were developed as part of this doctoral work.

The first method addresses the problem of disturbances in digital terrain models (DSMs) in small streams. Artificial intelligence was applied to interpret these disturbances and estimate water levels based on photogrammetric data. A convolutional neural network trained using supervised learning was employed for this purpose. Two model variants were tested: the first, simpler, used an encoder to transform the image into a single water level value, and a more complex method predicted a weight mask, which was then used for sampling the DSM, improving the accuracy and the explainability of the solution. In this second approach, a custom loss function was implemented, allowing the neural network to be trained without reference weight masks. Training data came from five case studies, and two cross-validation methods were used to evaluate the solution. One of them was the all-in-case-out method, allowing the model's effectiveness to be tested on a subset of data from a case study whose data was not used for training, confirming the model's ability to generalize. Depending on the case study and validation stringency, the proposed solution achieved a root mean square error (RMSE) ranging from 2 cm to 16 cm. This method outperforms traditional approaches based on simple photogrammetric DSM sampling, achieving an average of 62% lower RMSE for rigorous all-in-case-out validation. Using data from other studies, the proposed solution was compared in the same case study with other UAV-based methods. It achieved accuracy comparable to radar-based methods, considered the most accurate available for measuring water levels in small rivers using UAVs.

The second method dealt with the issue of low temperature measurement accuracy using thermal cameras mounted on UAVs. Limitations related to the maximum payload of UAVs necessitate the use of lightweight, uncooled thermal cameras whose internal components are not thermally stabilized. This leads to an increase in temperature measurement error from ± 0.5 °C in laboratory conditions to ± 5 °C in unstable flight conditions. The dissertation describes a data processing procedure that minimizes these undesirable effects. It consists of the following steps: (i) vignette removal using a single-image vignette correction algorithm, (ii) georeferencing using image metadata and gradient-based optimization, and (iii) optimizing temperature consistency between overlapping thermal images using gradient-based

optimization. The solution was tested in several river areas, where natural water bodies were used as a reference point for temperature. In the tests, the proposed method significantly improved measurement precision. The mean squared error (RMSE) decreased by an average of 39%, and the mean absolute error (MAE) by 40.5%. The proposed algorithm can be described as self-calibrating since it operates fully automatically, using only field data from standard aerial surveys and does not require additional calibration equipment or manual operator intervention.

The third project involved adapting the Priestley-Taylor Jet Propulsion Laboratory (PT-JPL) algorithm, originally developed for estimating evapotranspiration based on data from the ECOSTRESS satellite mission, for evapotranspiration calculations using data collected via UAVs. A two-day measurement campaign was conducted, during which data was collected from both UAVs and a meteorological station. This data was used to calculate evapotranspiration using the adapted PT-JPL algorithm and the eddy covariance method, which served as a reference measurement. The results showed high agreement with reference measurements, preliminarily confirming that the PT-JPL algorithm can be applied to measurements performed using UAVs.

1. Wstęp

1.1. Motywacja

Współczesne badania hydrologiczne stają przed licznymi wyzwaniami społecznymi, klimatycznymi, technologicznymi i analitycznymi. Zmiany klimatu, zwiększająca się częstotliwość ekstremalnych zjawisk pogodowych oraz rosnące zapotrzebowanie na zasoby wodne wymagają nowoczesnych metod monitorowania i modelowania procesów hydrologicznych. W obliczu tych wyzwań szczególne znaczenie zyskują bezzałogowe statki powietrzne, które umożliwiają precyzyjne zbieranie danych w czasie rzeczywistym oraz na dużych obszarach. Niemniej jednak, zastosowanie BSP w hydrologii wiąże się z szeregiem wyzwań technologicznych, takich jak dokładność pomiarów, integracja z innymi systemami monitorującymi oraz optymalizacja pracy czujników. Ponadto, złożona natura zbieranych danych wymaga zaawansowanych narzędzi analitycznych, w tym uczenia maszynowego, które pozwala na wykrywanie skomplikowanych wzorców. Uczenie maszynowe, choć obiecujące, stawia przed badaczami wyzwania związane z doбором odpowiednich algorytmów oraz interpretacją wyników, co podkreśla konieczność ścisłej współpracy między ekspertami z różnych dziedzin, w tym hydrologii, meteorologii i informatyki.


Niniejsza rozprawa doktorska poświęcona jest nowym metodom wspierania obserwacji hydrologicznych z wykorzystaniem bezzałogowych statków powietrznych oraz technik uczenia maszynowego, dążąc do wprowadzenia innowacyjnych rozwiązań w tej dziedzinie.

1.2. Cele pracy i hipotezy badawcze

Cele pracy zostały sformułowane w oparciu o rzeczywiste zapotrzebowanie, które zostało wskazane w aktualnej literaturze, a także z myślą o rozwiązaniu problemów, z którymi zetknęli się badacze z Zespołu Fizyki Środowiska Akademii Górniczo-Hutniczej w Krakowie.

Szacowanie poziomu wody małych strumieni przy pomocy fotogrametrii BSP i uczenia głębokiego

Pierwszym zagadnieniem poruszonym w pracy jest problem niedokładności szacowania poziomu wody w małych rzekach przy użyciu fotogrametrycznego numerycznego modelu pokrycia terenu (NMPT). Na rys. 1.2.1 przedstawiono przykładowe ortomozaiki rzek i odpowiadające im NMPT. Widzimy, że powierzchnia wody jest nieprawidłowo odwzorowana na NMPT. Zaburzenia nie są regularne – czasami występują bliżej środka koryta rzeki, a czasem przy jej brzegach.



Rys. 1.2.1. Fotogrametryczne ortomozaiki (po lewej) i odpowiadające im NMPT (po prawej). Skala NMPT wyrażona jest w m n.p.m.

Zaburzenia wynikają z nieprawidłowego odwzorowania powierzchni wód przez algorytm fotogrametryczny, co objawia się zaburzeniami na NMPT. Nasilenie oraz występowanie tych zaburzeń zdeterminowane jest wieloma czynnikami, takimi jak występowanie roślinności (zarówno przybrzeżnej jak i zanurzonej), stopień przejrzystości wody, głębokość i szerokość koryta, czy nachylenie brzegów.

W przypadku przejrzystych wód problemem jest odwzorowanie dna rzeki zamiast powierzchni wody. Z kolei w wodach nieprzejrzystych o jednolitej barwie pojawia się trudność z identyfikacją wystarczającej liczby punktów charakterystycznych, co prowadzi do mniej przewidywalnych błędów, objawiających się szumami sugerującymi nieprawidłowy poziom wody. Dodatkowym czynnikiem zakłócającym może być roślinność wystająca ponad powierzchnię wody. Tak złożone warunki trudno jest uwzględnić w tradycyjnych algorytmach, dlatego postawiono hipotezę, że uczenie maszynowe może zaoferować skuteczniejsze rozwiązania.

Uczenie maszynowe daje możliwość precyzyjnego modelowania złożonych zależności między różnymi czynnikami wpływającymi na dokładność pomiarów hydrologicznych. W przeciwieństwie do tradycyjnych algorytmów, które często polegają na statycznych, liniowych modelach, uczenie maszynowe pozwala na dynamiczną analizę danych o wielu zmiennych, co jest szczególnie istotne w środowisku naturalnym, gdzie warunki są zmienne i trudne do

przewidzenia. Dzięki algorytmom, takim jak sieci neuronowe, modele te mogą automatycznie uczyć się wzorców na podstawie dostępnych danych i dostosowywać swoje działanie do różnych scenariuszy. To oznacza, że systemy oparte na uczeniu maszynowym mogą uwzględniać takie czynniki jak zmiany w rodzaju roślinności, przejrzystości wody, czy sezonowe wahania poziomu rzeki.

Ponadto, techniki uczenia maszynowego pozwalają na ciągłe doskonalenie modelu wraz z gromadzeniem większej ilości danych. Modele te mogą uczyć się na podstawie nowych obserwacji i stale zwiększać swoją precyzję, co daje im przewagę nad tradycyjnymi metodami, które wymagają ręcznego dostrajania parametrów. Ostatecznie, zastosowanie uczenia maszynowego może znacząco poprawić dokładność szacowania poziomu wody w trudnych warunkach, gdzie konwencjonalne podejścia zawodzą.


Fotogrametryczny NMPT to trójwymiarowy model terenu, który można przekształcić w dwuwymiarową mapę wysokościową w formie rastra¹. W tym przypadku wartości przypisane poszczególnym pikselom odpowiadają wysokościami wyrażonym w metrach nad poziomem morza. Taki raster może być z powodzeniem interpretowany i analizowany przez splotowe sieci neuronowe (ang. Convolutional Neural Networks, CNN), które sprawdziły się jako skuteczne narzędzie w przetwarzaniu obrazów.

Automatyczna kalibracja lotniczych obrazów termowizyjnych przy użyciu optymalizacji metodą gradientów

Drugim problemem, którego podjęto próbę rozwiązania w niniejszej rozprawie jest niska dokładność pomiaru temperatury powierzchni terenu przy pomocy niechłodzonych kamer termowizyjnych zainstalowanych na pokładzie BSP. Niestabilne warunki meteorologiczne panujące podczas lotu oraz rozgrzewanie się komponentów kamery pod wpływem przepływu prądu elektrycznego powodują zwiększanie się niepewności pomiaru. Dotychczasowe metody redukcji niepewności opierają się na kalibracji na podstawie danych zebranych w kontrolowanych warunkach laboratoryjnych. Takie podejście wymaga zaawansowanego sprzętu laboratoryjnego (np. regulowane ciała doskonale czarne) oraz dodatkowego oprzyrządowania BSP (np. termometry). Wykonawca tego typu kalibracji musi posiadać specjalistyczną wiedzę oraz wykonać szereg manualnych czynności, co utrudnia automatyzację tych metod.

¹ Raster to cyfrowa reprezentacja obrazu lub powierzchni składająca się z prostokątnej siatki pikseli (komórek), gdzie każdy piksel posiada określoną wartość. W kontekście danych przestrzennych (GIS), raster jest używany do przechowywania danych takich jak obrazy satelitarne, zdjęcia lotnicze, dane topograficzne czy modele wysokościowe.

Problemy niechłodzonych kamer termowizyjnych objawiają się nieprawidłowymi pomiarami temperatury w początkowym etapie lotu BSP, podczas rozgrzewania się wewnętrznych komponentów kamery oraz skokowym dostrajaniem się kamery. Problemy te są szczególnie widocznie na mozaikach lotniczych zdjęć terenu, które przedstawiono na rys. 1.2.2 widzimy, że temperatury pomiędzy niektórymi kolejnymi przelotami różnią się znacząco, a także że kamera ma problemy z odpowiednim dostrojeniem w początkowej fazie lotu, szczególnie w zimie, gdy kamera musi rozgrzewać się od niskich temperatur początkowych.



Rys. 1.2.2. Przykładowe lotnicze mozaiki termiczne z widocznymi efektami dostrajania się kamery. Różnice pomiaru pomiędzy kolejnymi przelotami (rysunek po lewej) oraz problem z dostrojeniem w początkowej fazie lotu (rysunek po prawej).

Zdjęcia termowizyjne wykorzystywane do produkcji mozaik zazwyczaj cechują się pewnym stopniem przekrycia, czyli sąsiadujące zdjęcia częściowo przedstawiają ten sam obszar. Informacje z przekrywających się obszarów zdjęć są nadmiarowe i oba zdjęcia z pary przekrywających się zdjęć powinny wskazywać tą samą temperaturę w przekrywającym się obszarze, co w rzeczywistości nie zawsze jest spełnione. Fakt ten można wykorzystać do automatycznej kalibracji poprzez optymalizację minimalizującą różnice temperatury pomiędzy przekrywającymi się zdjęciami.

W ostatnich latach pod wpływem rozwoju sztucznej inteligencji szczególną uwagę w literaturze zaczęto zwracać na optymalizację metodą gradientów, wykorzystywaną do trenowania sieci neuronowych. W przypadku problemu kalibracji zdjęć termowizyjnych metoda gradientów może być szczególnie użyteczna dzięki swojej efektywności oraz sprawdzonego zastosowania w optymalizacji blokami danych. Jest to istotne, ponieważ minimalizacja różnic pomiędzy zdjęciami termowizyjnymi powinna być realizowana na dużym zbiorze danych wszystkich zdjęciach mozaiki równocześnie w celu zapewnienia wynikowych odczytów temperatury średnio jak najbardziej zbliżonych do średniej temperatury mozaiki sprzed kalibracji.

Szacowanie ewapotranspiracji na podstawie termografii BSP

Aktualne teledetekcyjne metody szacowania ewapotranspiracji stosowane są głównie dla pomiarów satelitarnych, które cechują się niską rozdzielczością przestrzenną i czasową. Bezzałogowe statki powietrzne stanowią ogniwo pośrednie między satelitami oferującymi pomiar na dużych obszarach ale o niskiej rozdzielczości i pomiarami miejscowymi takimi jak kowariancja wirów. BSP, pomimo możliwości pomiaru mniejszych obszarów, są konkurencyjne względem metod satelitarnych oferując wysoką rozdzielczość przestrzenną i elastyczność wyboru czasu pomiaru. Odgrywają one coraz większą rolę w szacowaniu ewapotranspiracji dzięki ich zdolności do dostarczania wysokorozdzielczych obrazów oraz danych na temat temperatury powierzchni i struktury roślinności (Niu i in., 2020).

Algorytm PT-JPL zastosowany w satelitarnej misji ECOSTRESS w celu teledetekcyjnego szacowania ewapotranspiracji nie został jeszcze przetestowany dla danych pozyskanych przy pomocy BSP. Stanowi to problem naukowy, którego zbadania podjęto się w niniejszej pracy.

Hipotezy badawcze

W rozprawie w szczególności postawiono następujące tezy badawcze:

1. Dzięki wykorzystaniu uczenia maszynowego można zwiększyć dokładność odczytu poziomu wody z fotogrametrycznego numerycznego modelu terenu stworzonego przy pomocy fotogrametrii BSP.

W celu przetestowania tej hipotezy zaplanowano następujące czynności badawcze:

- a) zebranie danych fotogrametrycznych obszarów rzek oraz wzorcowych pomiarów poziomu powierzchni wody w celu opracowania na ich podstawie zbioru danych do nadzorowanego treningu modelu uczenia maszynowego,
 - b) użycie metody siatki do znalezienia najlepszego modelu uczenia maszynowego przewidującego poziom powierzchni wody w małej rzece na podstawie danych fotogrametrycznych,
 - c) ewaluacja wytrenowanego modelu uczenia maszynowego poprzez porównanie z istniejącymi metodami wykorzystującymi bezzałogowe statki powietrzne.
2. Dzięki wykorzystaniu uczenia maszynowego możliwe jest zwiększenie dokładności pomiaru temperatury terenu wykonanego przy pomocy kamery termowizyjnej zainstalowanej na pokładzie BSP.

W celu przetestowania tej hipotezy zaplanowano następujące czynności badawcze:

- a) przeprowadzenie kampanii pomiarowych w celu pozyskania zdjęć termowizyjnych terenu przy pomocy BSP oraz pomiarów referencyjnych.
 - b) opracowanie algorytmu wykonującego georeferencję² zdjęć lotniczych,
 - c) opracowanie algorytmu uczenia maszynowego dostrajającego wartości zdjęć termowizyjnych w taki sposób, aby poprawić spójność odczytów temperatur między przekrywającymi się zdjęciami,
 - d) ewaluacja opracowanego rozwiązania poprzez porównanie wyników z pomiarami referencyjnymi.
3. Możliwe jest zaadaptowanie metody PT-JPL do oszacowania rozkładu ewapotranspiracji na powierzchni terenu przy pomocy pomiarów BSP.

W celu przetestowania tej hipotezy zaplanowano następujące czynności badawcze:

- a) zaadaptowanie algorytmu PT-JPL w celu użycia z danymi BSP,
- b) przeprowadzenie kampanii pomiarowej w celu pozyskania rastrowych danych teledetekcyjnych oraz danych meteorologicznych niezbędnych do obliczenia ewapotranspiracji przy pomocy zaadaptowanego modelu oraz metodą kowariancji wirów,
- c) porównanie wyników uzyskanych przy pomocy zaadaptowanego modelu i metody kowariancji wirów.

1.3. Struktura rozprawy

Rozprawa została podzielona na pięć części. Każdej z nich poświęcono oddzielny rozdział. Rozdziałem pierwszym jest niniejszy wstęp.

Rozdział drugi zawiera przegląd wiedzy literaturowej z wybranych zagadnień związanych z tematyką prac zrealizowanych w ramach doktoratu. Obejmują one:

- wybrane klimatyczne, społeczne, technologiczne i metodologiczne wyzwania hydrologii,
- ogólny przegląd metod pomiarowych w hydrologii,
- metody pomiaru poziomu powierzchni wody w małych rzekach ze szczególnym uwzględnieniem metod wykorzystujących bezzałogowe statki powietrzne,
- metody pomiaru temperatury powierzchni terenu ze szczególnym uwzględnieniem metod wykorzystujących bezzałogowe statki powietrzne,

² Georeferencja to proces przypisywania współrzędnych geograficznych (np. w układzie współrzędnych geograficznych lub w lokalnym układzie odniesienia) do obrazów lub danych rastrowych, takich jak mapy, zdjęcia satelitarne, czy ortofotomapy.

- metody pomiaru ewapotranspiracji ze szczególnym uwzględnieniem metod teledetekcyjnych.
- zastosowania uczenia maszynowego w hydrologii oraz szczegółowy opis metod uczenia maszynowego do przetwarzania obrazów.

Rozdział trzeci zawiera opis trzech metod opracowanych przez autora rozprawy oraz ilustrujących ich eksperymentów. Są to:

- szacowanie poziomu wody małych strumieni przy pomocy fotogrametrii BSP i uczenia głębokiego,
- automatyczna kalibracja lotniczych obrazów termowizyjnych przy użyciu optymalizacji metodą gradientów,
- szacowanie ewapotranspiracji na podstawie termografii BSP.

Pierwsza i druga metoda wykorzystuje techniki uczenia maszynowego. Trzecia metoda jest związana z drugą, gdyż kalibracja danych termowizyjnych wykorzystanych do teledetekcyjnego szacowania ewapotranspiracji wykonana jest algorytmem stworzonym w ramach metody drugiej.

Rozdział czwarty obejmuje prezentację i dyskusję wyników przeprowadzonych eksperymentów.

W rozdziale piątym podsumowano całość pracy, dokonano oceny trafności postawionych hipotez badawczych oraz wypunktowano działania opisane w rozprawie, które stanowią oryginalny wkład autora.

2. Bieżące osiągnięcia i wyzwania metod pomiarowych w hydrologii

2.1. Klimatyczne i społeczne wyzwania hydrologii

„Woda słodka jest najważniejszym zasobem dla ludzkości, przekrojowym dla wszystkich działań społecznych, gospodarczych i środowiskowych. Jest warunkiem wszelkiego życia na naszej planecie, czynnikiem umożliwiającym lub ograniczającym rozwój społeczny i technologiczny, możliwym źródłem dobrobytu lub nędzy, współpracy lub konfliktu” (UNESCO, 2023).

Czynniki antropogeniczne i zmiany klimatyczne wpływają na obieg wody, podaż i popyt na wodę oraz wywierają presję na globalne systemy wodne (Haddeland i in., 2014). Niosą one poważne zagrożenia dla społeczeństwa, nie tylko bezpośrednio poprzez zmiany w procesach hydrometeorologicznych, które regulują obieg wody, ale także pośrednio poprzez zagrożenia dla produkcji energii, bezpieczeństwa żywnościowego, rozwoju gospodarczego i nierówności społecznych (UNESCO, 2020).

Dowody naukowe na to, że klimat się ociepla, są obecnie jednoznaczne, a naukowcy są zgodni co do roli działalności człowieka. Antropogeniczne emisje gazów cieplarnianych (GC) gwałtownie wzrosły od ery przedindustrialnej. Pomimo pilnej potrzeby ich redukcji, obserwuje się przeciwny trend, szacując, że globalne antropogeniczne emisje GC netto wyniosły w 2019 r. około 12% więcej niż w 2010 r. i o 54% więcej niż w 1990 r. (IPCC, 2023).

Podczas gdy istnieje wyraźny trend wzrastającej globalnie temperatury, trendy w zakresie rocznych ilości opadów są znacznie bardziej niejednoznaczne w wielu regionach świata. Duża niepewność prognoz dotyczących zjawisk hydrologicznych, które oparte są na modelach klimatycznych (M. Shen i in., 2018; Yazdandoost i in., 2021) nie wyklucza potencjalnie dużego wpływu zmian klimatu na ekstremalne zjawiska pogodowe i zasoby wodne. Nawet niewielkie zmiany temperatury i klimatu, przewidywane w optymistycznych scenariuszach niskiej emisji GC, mogą mieć duży wpływ na dostępność wody, a zwłaszcza na ekstremalne warunki pogodowe (IPCC, 2023). Prognozy klimatyczne wskazują, że ekstremalne opady staną się bardziej intensywne i częstsze w wielu regionach, co zwiększy ryzyko powodzi (Hirabayashi i in., 2013), ale także, że fale upałów i susze będą występować częściej i trwać dłużej (Trenberth i in., 2014).

Zmiany opadów i temperatury będą miały bezpośredni wpływ na lądowy bilans wodny (Schewe i in., 2014), a zarazem na bilans energii na powierzchni Ziemi (Trenberth i in., 2009). Oczekuje się, że parowanie z powierzchni ziemi wzrośnie w wyniku globalnego trendu wzrostu temperatury powietrza. W niektórych regionach wzrost parowania może zostać zrównoważony

przez zwiększone opady, jednak w wielu przypadkach zaistniałe zmiany mogą doprowadzić to do zmniejszenia przepływu strumieni i zmniejszenia dostępności wody w różnych porach roku (IPCC, 2018). Takie spadki mają bezpośredni wpływ na dostępność wody, w przypadku poboru wody na potrzeby rolnictwa, przemysłu i gospodarstw domowych, wytwarzanie energii, żegluga, rybołówstwa, rekreacji i, co nie mniej ważne, środowiska (UNESCO, 2020).

Zmiany klimatu mają wpływ na zasoby wód powierzchniowych i podziemnych. Ze względu na różne skale czasowe zaangażowanych procesów, wpływ suszy na deficyt wód podziemnych (choć zwykle jest mniej wyraźny niż w przypadku wód powierzchniowych i pojawia się z opóźnieniem) może trwać znacznie dłużej niż pierwotna susza meteorologiczna, która je spowodowała. Wpływ na dostęp do wody mogą mieć również powodzie powodujące zanieczyszczenie zbiorników i zniszczenia infrastruktury (UNESCO, 2020).

Powszechne są również wywołane zmianami klimatu zmiany w kriosferze, prowadzące do globalnego zmniejszenia pokrywy śnieżnej i lodowej (Huss i in., 2017). Chociaż przyspieszone topnienie lodowców może lokalnie i tymczasowo zwiększyć przepływ w ciekach, zmniejszenie pokrywy lodowców zwykle prowadzi do zmniejszenia przepływu w dłuższej perspektywie, a także do bardziej nieprzewidywalnej zmienności przepływów (UNESCO, 2020). Dodatkowo, topnienie lodowców i śniegu prowadzi do obniżenia albedo powierzchni Ziemi, co powoduje wzrost absorpcji promieniowania słonecznego. To z kolei przyspiesza proces ocieplania się powierzchni, co stanowi przykład sprzężenia zwrotnego wzmacniającego zmiany klimatyczne.

W ciągu ostatnich 40 lat zużycie wody rosło na całym świecie o około 1% rocznie i oczekuje się, że będzie rosło w podobnym tempie do 2050 roku, napędzane przez połączenie wzrostu liczby ludności, rozwoju społeczno-gospodarczego i zmieniających się wzorców konsumpcji. (UNESCO, 2023).

Połączone skutki wzrostu liczby ludności, rosnącego zapotrzebowania na wodę w celu wspierania rolnictwa, bezpieczeństwa energetycznego i ekspansji przemysłowej oraz wyzwań związanych ze zmianami klimatu powodują pilną potrzebę uważnego monitorowania i oceny trendów i wahań zasobów wodnych. Dzięki temu zrównoważony dostęp do odpowiednich ilości bezpiecznej i zdanej do użytku wody będzie stanowił podstawę bezpieczeństwa wodnego. W związku z tym istnieje pilna potrzeba zwiększenia wysiłków w monitorowaniu zasobów wodnych zarówno przy pomocy metod *in situ* jak i teledetekcji (Lawford i in., 2013). Opinię tę potwierdzono również w ankiecie, gdzie 336 hydrologów wypowiedziało się na temat roli pracy eksperymentalnej w naukach hydrologicznych (Blume i in., 2016). Ankietowani wskazali, że istnieje potrzeba rozwoju nowych metod i narzędzi pomiarowych, a także przeprowadzania większej liczby pomiarów i zwiększenia wysiłków utrzymywania sieci

monitoringu. Większość uczestników zauważyło, że w ostatnich latach istnieje ogólna tendencja do większej eksploracji danych i modelowania, a mniej badań eksperymentalnych.

2.2. Wyzwania metod pomiarowych w hydrologii

Pomiary w hydrologii pełnią kluczową rolę w zrozumieniu i monitorowaniu procesów wodnych, umożliwiając śledzenie zmian w obiegu wody oraz prognozowanie skutków ekstremalnych zjawisk pogodowych. Za pomocą różnorodnych technik pomiarowych, takich jak pomiary ilości opadów atmosferycznych, parowania, wilgotności gleby, poziomu wód powierzchniowych i podziemnych, przepływu w rzekach czy też analizy jakości wody, gromadzone są dane niezbędne dla weryfikacji i walidacji modeli matematycznych i opracowania strategii zarządzania zasobami wodnymi.

Tradycyjne metody pomiarowe hydrologii polegają na obserwacjach prowadzonych w punktach pomiarowych. Uznawane są one za najlepsze źródło wzorcowych informacji o opadach, jako że dostarczają one bezpośredniego, fizycznego pomiaru w danym miejscu (Tapiador i in., 2012). Jedną z podstawowych technik monitorowania opadów atmosferycznych jest stosowanie deszczomierzy. Pomiar poziomu wód powierzchniowych, takich jak rzeki, jeziora czy stawy, przeprowadza się za pomocą wodowskazów. Do badania poziomu wód podziemnych stosuje się studnie i studzienki piezometryczne. Ponadto, pomiary jakości wody, takie jak analiza składu chemicznego czy zawartości substancji zanieczyszczających, są wykonywane przy użyciu próbek wody pobranych z różnych źródeł, a następnie analizowanych w laboratorium. Opracowano wiele wariantów wymienionych rozwiązań pomiarowych, różniących się fizycznymi podstawami działania czy też stopniem automatyzacji. Pomimo punktowego charakteru pomiarów, odpowiednie umiejscowienie stacji pomiarowej pozwala na uzyskanie odczytów charakteryzujących większy obszar. Powszechne są pomiary przepływu w rzekach w miejscach ujścia ze zlewni pozwalające na pomiar odpływu, będącego kluczowym składnikiem bilansu wodnego zlewni (Davie, 2019). Innym przykładem jest szacowanie ładunku zanieczyszczeń i ilości dopływu słodkiej wody z danego terytorium do morza (np. w przypadku Polski wystarczy monitoring w punktach ujścia Wisły i Odry) (Voss i in., 2006).

Pomimo wyzwań związanych z przemianami socjoekonomicznymi i klimatycznymi, obserwuje się podupadanie istniejących sieci monitoringu poprzez zmniejszanie ilości stacji oraz brak utrzymywania ciągłości pomiarów (Mishra & Coulibaly, 2009; Sheffield i in., 2018; Shiklomanov i in., 2002). Zbiory danych z pomiarów punktowych często nie zachowują wspólnych standardów i nie obejmują wielu trudno dostępnych obszarów (Chawla i in., 2020).

W ciągu ostatnich kilku dekad problemy te rozwiązywane były przez samoloty i satelity będące głównym źródłem pomiarów teledetekcyjnych.

Użyteczność satelitów lub samolotów ogranicza się do największych skal przestrzennych, a także rozdzielczość czasowa ograniczana jest przez harmonogramy przelotów satelitów i wysokie koszty użycia samolotów (Acharya i in., 2021). Luka informacyjna powstała pomiędzy pomiarami punktowymi, a wielkoskalową teledetekcją, może być zapełniona przez pomiary wykonywane z użyciem bezzałogowych statków powietrznych (BSP), które w ostatnich latach zwiększyły swoją popularność dzięki postępom w rozwoju robotyki, sieci bezprzewodowych, akumulatorów, czujników, systemów przetwarzania obrazów i oprogramowania (Acharya i in., 2021; Chabot, 2018).

2.3. Bezzałogowe statki powietrzne w hydrologii

Bezzałogowe statki powietrzne (BSP) o skrzydłach stałych i wirnikowce są dwiema najczęściej wykorzystywanymi platformami lotniczymi w hydrologii. Wybór platformy jest uzależniony od celów i zakresu badania w odniesieniu do wymaganego obciążenia, zasięgu lotu, wymagań dotyczących manewrowości itp. Stałopłaty wykorzystują skrzydła do generowania siły nośnej i sterowania lotem. Mają większy zasięg, większą ładowność i większą prędkość lotu, ale do wytwarzania siły nośnej wymagana jest minimalna prędkość, poniżej której dochodzi do przeciągnięcia. Z kolei BSP z napędem wirnikowym wykorzystują śmigła do generowania siły nośnej i sterowania lotem. Ze względu na swój charakter, wirnikowce są bardzo zwrotne i mają zdolność pionowego startu i lądowania. Mają jednak niższe prędkości lotu i są bardziej ograniczone pod względem wysokości i czasu trwania lotu ze względu na wysokie wymagania energetyczne związane z utrzymaniem siły nośnej. Czujnikami najczęściej wykorzystywanymi w badaniach hydrologicznych są kamery RGB, multispektralne, hiperspektralne, termowizyjne, a także dalmierze laserowe, skanery LIDAR, oraz radary. BSP znajdują wiele zastosowań, takich jak pomiar poziomu lustra wód powierzchniowych, pomiar głębokości zbiorników wodnych, pomiar prędkości i wielkości przepływu w rzekach, pobieranie próbek wody do celów analizy chemicznej, obserwacja rozkładu przestrzennego i grubości śniegu oraz lodu, obserwacji skutków powodzi oraz suszy, szacowanie wilgotności gleby, szacowanie parowania i transpiracji, monitorowanie zanieczyszczeń wody, czy też dostarczanie informacji dla celów rolniczych (Acharya i in., 2021). Podczas ostatniej powodzi na południu Polski (wrzesień 2024), BSP wyposażone w kamery termowizyjne zostały także wykorzystane do identyfikowania przecieków w wałach przeciwpowodziowych.

Szczególne znaczenie w kontekście prac opisywanych w rozprawie mają pomiary poziomu powierzchni małych rzek oraz temperatury powierzchni terenu wykonywane przy pomocy BSP. Zostały one szczegółowo opisane w dwóch kolejnych podrozdziałach.

2.4. Pomiar poziomu powierzchni małych rzek przy pomocy BSP

2.4.1. Metody pomiaru poziomu powierzchni małych rzek przy pomocy BSP

Małe rzeki pierwszego i drugiego rzędu (według klasyfikacji Strahlera) (Strahler, 1957) stanowią 70-80% długości wszystkich rzek na świecie, odgrywają znaczącą rolę w systemach hydrologicznych oraz są ekosystemem dla organizmów żywych (Wohl, 2017). Pomiary satelitarne o ograniczonej rozdzielczości przestrzennej nie są w stanie zaoferować użytecznych pomiarów poziomu powierzchni wody dla małych strumieni. W tym względzie techniki pomiarowe oparte na BSP są obiecujące w wielu kluczowych aspektach, ponieważ w porównaniu do pomiarów satelitarnych, zapewniają obserwacje w wysokiej rozdzielczości przestrzennej i czasowej, a także ich użycie jest stosunkowo szybkie oraz w przeciwieństwie do pomiarów in-situ łatwiejsze jest ich stosowanie w niedostępnych lokalizacjach.

W przypadku metod wykorzystujących pomiar wysokości BSP nad lustrem wody niezbędna jest precyzyjna lokalizacja BSP. Dzięki uzyskaniu wysokości BSP powyżej elipsoidy³ odniesienia (lub poziomu morza, jeśli znana jest wysokość geoidy⁴), można obliczyć wysokość lustra wody poprzez odjęcie wysokości BSP nad powierzchnią wody od absolutnej wysokości BSP (Bandini i in., 2020). Rozwiązania pozycjonujące wykorzystujące wyłącznie technologie GNSS (ang. global navigation satellite system) takie jak GPS (ang. global positioning system) nie dostarczają wystarczająco dokładnych informacji o pozycji BSP, jako że w 95% pomiarów błąd lokalizacji przy pomocy GPS w poziomie wynosi do 1.822 m, a w pionie do 4.524 m (GPS Standard Positioning Service Performance Analysis Report, 2021). W celu poprawy dokładności lokalizacji BSP wykorzystuje się poprawki obliczane na podstawie technik różnicowych, spośród których można wyróżnić dwie najczęściej stosowane w pomiarach BSP metody: RTK (ang. real-time kinematic) pozwalająca na uzyskanie poprawek lokalizacji w czasie rzeczywistym, czyli podczas lotu BSP, a także metodę PPK (ang. post-processed kinematic) pozwalającą na korekcję pozycjonowania zebranych danych po zakończeniu lotu BSP. W systemach różnicowych poprawki obliczane są na podstawie danych dostarczanych z

³ Elipsoida odniesienia to uproszczony model Ziemi, który zakłada jej kształt jako elipsoidę obrotową.

⁴ Wysokość geoidy (zwana również undulacją geoidy) to różnica pomiędzy wysokością elipsoidy odniesienia (idealnej matematycznej powierzchni opisującej Ziemię) a poziomem geoidy (czyli rzeczywistą powierzchnią, na której potencjał grawitacyjny jest wszędzie taki sam). Geoidę można sobie wyobrazić jako powierzchnię, która odpowiada średniemu poziomowi mórz i oceanów, gdyby nie było fal, przypliwów ani innych zakłóceń.

naziemnej stacji bazowej o znanych koordynatach. Stacją bazową może być zarówno przenośne urządzenie zainstalowane tymczasowo na potrzeby lotu BSP (Bandini i in., 2020), jak również można skorzystać z usług sieci stałych stacji bazowych (Tomašík i in., 2019). W Polsce siecią stałych stacji bazowych jest ASG-EUPOS, w skład której wchodzi 84 stacje rozmieszczone równomiernie na terenie całego kraju. Niepewność lokalizacji przy pomocy metod RTK/PPK zależy od odległości od stacji bazowej i mieści się w przedziale od 1 cm do 3 cm zarówno dla pomiarów w poziomie jak i pionie (Öğütçü & Kalaycı, 2018). Dodatkowe zwiększenie dokładności oraz częstotliwości lokalizacji BSP uzyskuje się przez integrację systemów GNSS z odczytami z modułu IMU (ang. inertial measurement unit) znajdującego się na pokładzie BSP (Bandini i in., 2020; Falco i in., 2017). IMU pozwala na pomiar przyśpieszenia, szybkości kątowej oraz orientacji przestrzennej BSP przy użyciu kombinacji akcelerometrów i żyroskopów i kompasów (Ahmad i in., 2013; Stöcker i in., 2017). Rzadziej spotykanymi metodami uzyskiwania poprawek lokalizacji BSP są algorytmy wykorzystujące analizę wizyjną otoczenia takie jak VO (ang. visual odometry), czy SLAM (ang. simultaneous localisation and mapping) (Balamurugan i in., 2016). Aktualne metody wykorzystujące BSP do pomiaru poziomu lustra wody małych rzekach bazują na rozwiązaniach wykorzystujących pomiar pionowego dystansu pomiędzy dronem a powierzchnią wody przy pomocy różnego rodzaju dalmierzy (np. radaru, dalmierza laserowego, sonaru) (Bandini i in., 2017) lub rozwiązaniach pozwalających na utworzenie numerycznego modelu pokrycia terenu (NMPT) lub chmury punktów osadzonych w geograficznym układzie odniesienia, z których następnie można odczytać poziom wody (Bandini i in., 2020). Teledetekcyjne metody określania poziomu wody wykorzystujące NMPT lub chmury punktów realizowane są przy pomocy fotogrametrii lub skaningu laserowego.

Fotogrametria jest techniką tworzenia trójwymiarowych modeli na podstawie zdjęć przedstawiających modelowany obiekt. Główne etapy przetwarzania fotogrametrycznego to i) stereowizja: identyfikowane są wspólne punkty na zdjęciach, które przedstawiają ten sam obiekt z różnej perspektywy, ii) triangulacja: wykorzystując podobieństwa trójkątów obliczane są odległości i kąty między parami punktów stereoskopowych, iii) rekonstrukcja trójwymiarowa: na podstawie danych pozyskanych z procesu triangulacji zrekonstruowany zostaje trójwymiarowy model obiektu w postaci chmury punktów lub siatki trójkątów. Fotogrametria znalazła szerokie zastosowanie w mapowaniu terenu. Wykorzystuje się ją do generowania ortofotomap i numerycznych modeli pokrycia terenu (NMPT). Ortofotomapa to dwuwymiarowy obraz przedstawiony w nawiązaniu do geograficznego układu współrzędnych ukazujący teren z perspektywy „lotu ptaka”. W przeciwieństwie do nieprzetworzonego zdjęcia

lotniczego charakteryzuje się rzutem ortogonalnym (każdy piksel ortofotomapy przedstawiony jest z perspektywy pionowej do powierzchni terenu). NMPT to trójwymiarowy model odwzorowujący ukształtowanie terenu, uwzględniający szatę roślinną i zabudowania. Nie należy go mylić z numerycznym modelem terenu, który przedstawia sam teren pozbawiony roślin i zabudowań. Pomiaru poziomu powierzchni wody można dokonać poprzez próbkowanie NMPT na interesującym nas obszarze wody. Zadanie to jest jednak utrudnione z powodu zaburzeń występujących na odwzorowanej fotogrametrycznie powierzchni wody, związanych z ograniczeniami tej metody. Problem ten zostanie bardziej szczegółowo opisany w podrozdziale 2.4.2.

Skaning laserowy LIDAR (ang. light detection and ranging) jest innym sposobem tworzenia chmur punktów lub NMPT. Podczas użycia LIDAR do pomiaru poziomu lustra wody, należy zwrócić uwagę na częstotliwość światła emitowanego przez laser. Bliska podczerwień jest odbijana przez powierzchnię wody i nie przenika poniżej jej poziomu, podczas gdy niebieskie/zielone światło przenika poniżej powierzchni wody powodując sygnały rozproszone na różnych głębokościach wody i na dnie. Z tego powodu odradza się używanie w tego typu zastosowaniach światła zielonego (Guenther i in., 2000) i większość rozwiązań wykorzystuje bliską podczerwień (Brzank i in., 2008; Collin i in., 2008; Höfle i in., 2009). Ponieważ światło zielone przenika pod powierzchnię wody, LIDAR wykorzystujący to światło jest stosowany w zadaniach batymetrycznych, takich jak mapowanie dna i pomiar głębokości. Niemniej jest to możliwe tylko dla wystarczająco przejrzystych i płytkich zbiorników (Allouis i in., 2010; Mandlbürger i in., 2016).

Aby możliwe było odczytanie z NMPT lub chmury punktów poziomu lustra wody muszą one być zlokalizowane w układzie odniesienia. Georeferencja NMPT lub chmury punktów może być zrealizowana przy pomocy naziemnych punktów referencyjnych, czyli punktów znajdujących się na mapowanym terenie mających znane współrzędne. W przypadku użycia naziemnych punktów referencyjnych nie ma potrzeby dokładnego pozycjonowania BSP przy pomocy np. RTK.

W bezpośrednim porównaniu użycia radaru, LIDARU oraz fotogrametrii w zadaniu teledetekcyjnego określania poziomu lustra wody przy pomocy BSP, najdokładniejszym narzędziem okazał się radar uzyskując błąd średniokwadratowy równy 3 cm, podczas gdy na tym samym odcinku rzeki fotogrametria i LIDAR uzyskały wyniki odpowiednio 16 cm oraz 22 cm (Bandini i in., 2020). Metoda oparta na radarze cechuje się krótkim czasem akwizycji i przetwarzania danych. Niemniej, metoda ta wymaga precyzyjnej geolokalizacji BSP przy pomocy RTK lub PPK. W badaniu, z którego pochodzą przytoczone wyniki w metodzie

wykorzystującej radar użyto poprawek lokalizacji PPK uzyskanych przy pomocy tymczasowej stacji bazowej umiejscowionej w pobliżu badanego obszaru. Należy więc do kosztów tego typu pomiaru doliczyć koszt stacji bazowej. Dokładność poprawek RTK/PPK zależy od odległości od stacji bazowej. Możliwe jest więc, że w przypadku wykorzystania bardziej odległej stacji należącej do sieci stałych stacji bazowych, dokładność metody opartej na radarze może być gorsza niż zaprezentowana w badaniu. W tym aspekcie metody oparte na NMPT lub chmurze punktów mogą być lepszym rozwiązaniem. W szczególności ma to miejsce przy powtarzanych wielokrotnie pomiarach na tym samym obszarze, ponieważ w takim przypadku wymagane jest tylko jednorazowe wytyczenie naziemnych punktów referencyjnych, z których można korzystać w każdym kolejnym pomiarze na danym obszarze.

2.4.2. Problem odwzorowania powierzchni wody na fotogrametrycznym NMPT

W poprzednim podrozdziale przytoczona została metoda wykorzystująca fotogrametrię BSP do określania poziomu powierzchni wody w małych rzekach. Fotogrametryczne NMPT oferują wysoką precyzję określania wysokości powierzchni stałych z dokładnością do kilku centymetrów (Bühler i in., 2017; Ouédraogo i in., 2014), jednak powierzchnie wody zwykle są odwzorowane znacznie mniej dokładnie. Związane jest to z ograniczeniami algorytmu fotogrametrycznego, który opiera się na automatycznym wyszukiwaniu wyróżniających się i statycznych punktów terenu, które pojawiają się na kilku obrazach, ukazujących te punkty z różnych perspektyw. Powierzchnia wody nie posiada takich punktów, gdyż jest jednorodna, przezroczysta i w ruchu. Przezroczystość wody sprawia, że poziom powierzchni strumienia na fotogrametrycznym NMPT jest niższy niż w rzeczywistości. W przypadku przejrzystych i płytkich strumieni fotogrametryczne NMPT odwzorowują powierzchnie dna (Kasvi i in., 2019). Fotogrametryczne NMPT dla nieprzejrzystych zbiorników wodnych są obarczone artefaktami spowodowanymi brakiem wyróżniających się punktów charakterystycznych (Woodget i in., 2014). Powyższe czynniki sprawiają, że pomiar poziomu powierzchni wody poprzez bezpośrednie próbkowanie NMPT prowadzi do wyników o dużej niepewności. Niektóre badania wskazują, że możliwe jest odczytanie poziomu powierzchni wody z fotogrametrycznego NMPT w pobliżu brzegu strumienia, gdzie strumień jest płytki i nie występują niepożądane efekty związane z przenikaniem światła poniżej powierzchni wody (Javernick i in., 2014; Pai i in., 2017; Woodget i in., 2014). Jednak ta metoda daje zadowalające wyniki tylko w przypadku nieporośniętych roślinnością i łagodnie nachylonych brzegów strumienia, gdzie linia graniczna między wodą a lądem jest łatwa do zdefiniowania (Bandini i

in., 2020). Z tego powodu metoda ta nie nadaje się do wielu strumieni, które nie spełniają tych warunków.

2.5. Termografia BSP


2.5.1. Fizyczne podstawy termografii

Termografia (lub obrazowanie termiczne) jest techniką generowania radiometrycznych obrazów cyfrowych zarejestrowanych w zakresie elektromagnetycznych fal podczerwieni o długości od 0,8 do 15 μm . Pozwala ona na wizualizację jakościową i ilościowy pomiar temperatury powierzchni bez potrzeby fizycznego kontaktu czujnika z badanym obiektem (Vollmer & Möllmann, 2017).

Termografia opiera się na detekcji promieniowania, które emitowane jest przez każde ciało. Promieniowanie to zwane jest promieniowaniem termicznym i zależy od temperatury ciała i materiału jego powierzchni (Mandl, 2013). Widmo promieniowania termicznego opisane jest prawem Plancka dla ciała doskonale czarnego, czyli wyidealizowanego ciała pochłaniającego całość padającego na nie promieniowania. Równanie 2.5.1.1 przedstawia przykładowy sposób wyrażenia prawa Plancka przy pomocy radiancji spektralnej przypadającej na jednostkę długości fali (Caniou, 1999; Modest, 2013):

$$L_{\lambda}(\lambda, T) = \frac{2 hc^2}{\lambda^5} \frac{1}{e^{hc/\lambda k_B T} - 1} , \quad (2.5.1.1)$$

gdzie h – stała Plancka, c – prędkość światła w próżni, λ – długość fali promieniowania, k_B – stała Boltzmann, T – temperatura ciała doskonale czarnego. Na rys. 2.5.1.1 przedstawiono widma promieniowania termicznego emitowanego przez ciała doskonale czarne o różnych temperaturach. Wraz ze wzrostem temperatury ciała rośnie pole pod wykresem widma, a więc również ilość całkowitej wypromieniowanej energii (prawo Stefana–Boltzmann) oraz maleje długość fali promieniowania o największym natężeniu (prawo Wiena).



Rys. 2.5.1.1. Widma promieniowania termicznego wyemitowanego przez ciała doskonale czarne o różnych temperaturach (linie ciągłe). Linie przerywane wyznaczają długości fali promieniowania o największym natężeniu.

W rzeczywistości obiekty nie emitują promieniowania cieplnego zdefiniowanego wedle wyidealizowanej teorii ciała doskonale czarnego, a tylko jego część. O tym, jak duża jest to część decyduje współczynnik emisyjności ϵ . Zdefiniowany jest on jako stosunek ilości promieniowania faktycznie emitowanego z powierzchni do promieniowania emitowanego przez ciało doskonale czarne w tej samej temperaturze. Współczynnik emisyjności zależy przede wszystkim od materiału powierzchni, ale również od struktury powierzchni, kąta obserwacji, długości fali emitowanego promieniowania, czy temperatury obiektu (Vollmer & Möllmann, 2017).

Kamery termowizyjne, podobnie do standardowych kamer cyfrowych rejestrujących obrazy z pasma widzialnego, wykorzystują matryce czujników rejestrujących promieniowanie. Można wyróżnić dwa rodzaje czujników wykorzystywanych w termografii: kwantowe czujniki fotonów oraz czujniki bazujące na pomiarze zmian temperatury elementu, na który pada promieniowanie termiczne.

Działanie czujników fotonów opiera się na zjawisku wewnętrznego efektu fotoelektrycznego, w którym fotony padającego promieniowania termicznego dostarczają energię elektronom z pasma walencyjnego półprzewodnika i przenoszą je do pasma przewodzenia generując sygnał elektryczny. Elektrony walencyjne mogą zostać wzbudzone również przez energię termiczną półprzewodnika. Z tego powodu, aby uniknąć szumów, takie

czujniki często muszą być schładzane nawet do temperatury 77 K (Vollmer & Möllmann, 2017).

Najczęściej używanym w termografii czujnikiem bazującym na pomiarze temperatury jest mikrobolometr. Głównym elementem mikrobolometru jest membrana ogrzewająca się pod wpływem absorbowanego przez nią promieniowania, co powoduje wzrost oporu elektrycznego membrany, który jest mierzony i zamieniany na sygnał cyfrowy o wielkości w przybliżeniu proporcjonalnej do zaabsorbowanej energii. Czułość mikrobolometru zależy jest od temperaturowego współczynnika rezystancji określającego stosunek zmian oporu elektrycznego do zmiany temperatury. Z tego powodu membrany wykonywane są aktualnie z półprzewodników takich jak tlenek wanadu (V), czy krzem amorficzny, które w porównaniu do metali mają o rząd wielkości większy temperaturowy współczynnik rezystancji. Aby zminimalizować bezwładność temperaturową i tym samym zapewnić możliwie krótki czas odpowiedzi czujnika, membrany muszą mieć niewielką grubość około 0.2 μm . Jest ona zbyt mała, aby absorbować całe nadchodzące promieniowanie podczerwone. Membrany są uniesione na wysokość równą $\frac{1}{4}$ przewidywanej długości fali padającego promieniowania ponad podłożem, tworząc w ten sposób wnękę rezonansową ułatwiającą absorpcję promieniowania w membranie. Uniesienie membrany ponad podłoże przyczynia się także do izolacji cieplnej, co redukuje szum czujnika (Vollmer & Möllmann, 2017).

2.5.2. Problemy niechłodzonych kamer termowizyjnych

Mikrobolometry w przeciwieństwie do większości czujników fotonów nie muszą być chłodzone i mogą operować w temperaturze pokojowej. Użycie mikrobolometrów zmniejszyło rozmiary i masę kamer termowizyjnych, co umożliwiło ich użycie w bezzałogowych statkach powietrznych. Pomimo użycia metod mających na celu poprawę stabilności i zwiększenie dokładności pomiarów temperatury, niechłodzone kamery mikrobolometryczne wciąż ustępują w tych kwestiach kamerom chłodzonym. Kamery niechłodzone są w większym stopniu wrażliwe na rozgrzewanie wewnętrznych komponentów pod wpływem przepływu prądu, ale również na zmiany temperatury otoczenia, zmienne warunki promieniowania słonecznego, czy powiewy wiatru, które są szczególnie istotne podczas pracy kamery umieszczonej na pokładzie BSP (Aragon i in., 2020; Kelly i in., 2019; Kusnierek & Korsæth, 2014; Yuan & Hua, 2022). Wpływ warunków środowiskowych powoduje wzrost niepewności pomiaru temperatury z wartości $\pm 0.5\text{ }^{\circ}\text{C}$ możliwej do uzyskania w warunkach laboratoryjnych do $\pm 5\text{ }^{\circ}\text{C}$ w niestabilnych warunkach lotu BSP (Kelly i in., 2019). Niepożądanymi efektami braku

stabilizacji temperatury mikrobolometrów użytych w niechłodzonych kamerach są na przykład efekt winiety⁵, czy też dryf wartości zmierzonych temperatur.

Aby zminimalizować niekorzystne efekty związane z niestabilnością temperatury mikrobolometrów, zaleca się 15–40 minutowe „rozgrzewanie” kamery przed rozpoczęciem docelowego pomiaru (Kelly i in., 2019; Yuan & Hua, 2022). Opracowano również metody kalibracji w kontrolowanych warunkach przy pomocy wzorcowych ciał doskonale czarnych. Możliwa jest kalibracja realizowana przy pomocy funkcji liniowej, wielomianowej lub sieci neuronowej, których parametrem jest temperatura czujników kamery (Ribeiro-Gomes i in., 2017). Podobnie możliwa jest kalibracja parametryzowana temperaturą otoczenia (Aragon i in., 2020). Testowano również bardziej złożone metody kalibracji w warunkach laboratoryjnych (Lin i in., 2018). Efekt winiety może zostać skompensowany przy pomocy pomiarów z użyciem obiektu referencyjnego o jednorodnym rozkładzie temperatur (Yuan & Hua, 2022).

Wadą metod opartych na kalibracji przy pomocy pomiarów uzyskanych w kontrolowanych warunkach laboratoryjnych jest to, że wymagają one niestandardowego sprzętu i dodatkowego wysiłku potrzebnego do zebrania danych kalibracyjnych. Preferowana byłaby korekta oparta wyłącznie na danych terenowych zebranych podczas lotu BSP. Zaproponowana została tego typu metoda korekcji błędu pomiaru temperatury z wykorzystaniem nadmiarowych danych zaczerpniętych z nakładających się obszarów lotniczych zdjęć (Mesas-Carrascosa i in., 2018). Metoda ta wymaga jednak precyzyjnego pomiaru czasu akwizycji obrazu uzyskanego za pomocą niestandardowego oprzyrządowania BSP. W standardowych rozwiązaniach BSP informacje o czasie akwizycji obrazu dostępne są z rozdzielczością jednej sekundy, co nie jest wystarczające, ponieważ podczas lotu kolejne zdjęcia są wykonywane nawet co około 1 s.

Częstym problemem występującym w wielu komercyjnie dostępnych kamerach termowizyjnych jest brak możliwości samodzielnej kalibracji radiometrycznej spowodowany ukryciem logiki przetwarzania surowych danych przy pomocy oprogramowania o zamkniętym źródle. Niemożliwe jest wtedy użycie opisanych powyżej technik kalibracji, które operują na surowych danych i trzeba polegać na kalibracji wykonanej przez producenta. Nie można też mieć pewności, co do szczegółów algorytmów użytych do obliczania temperatury.

⁵ Efekt winiety, winietowanie – występowanie odczytów temperatury o obniżonej wartości na pikselach przy krawędzi zdjęcia termicznego. W klasycznej fotografii przyciemnienie zdjęcia przy jego krawędzi.

2.6. Ewapotranspiracja

2.6.1. Procesy ewapotranspiracji i jej czynniki determinujące

Połączenie dwóch oddzielnych procesów, w których woda tracona jest z powierzchni gleby przez parowanie oraz z roślin przez transpirację jest nazywane ewapotranspiracją (ET).

Parowanie to proces, w którym ciekła woda jest przekształcana w parę wodną i usuwana z parującej powierzchni. Do zmiany stanu cząsteczek wody z ciekłego na gazowy potrzebna jest energia. Bezpośrednie promieniowanie słoneczne oraz, w mniejszym stopniu, przewodnictwo ciepła z podłoża i otaczającego powietrza dostarczają tej energii. W zależności od rodzaju powierzchni, z której zachodzi parowanie – czy jest to wolna powierzchnia wody, krople wody, czy gleba – proces ten może przebiegać w różny sposób. W przypadku swobodnej powierzchni wody, parowanie zachodzi bezpośrednio z tafli wody, podczas gdy parowanie z gleby czy kropeł wody może być ograniczone przez różne warunki środowiskowe, takie jak struktura gleby czy wielkość kropli.

Jednym z czynników napędzających usuwanie pary wodnej z powierzchni jest różnica między ciśnieniem pary wodnej na parującej powierzchni a ciśnieniem otaczającej atmosfery. W miarę parowania powietrze w pobliżu powierzchni staje się stopniowo nasycone, a proces spowalnia i może zostać zatrzymany, jeśli wilgotne powietrze nie zostanie przeniesione do wolnej atmosfery. Wymiana nasyconego powietrza na bardziej suche poprzez mieszanie zależy w dużej mierze od prędkości wiatru. W związku z tym promieniowanie słoneczne, temperatura powietrza, wilgotność powietrza i prędkość wiatru są parametrami meteorologicznymi które należy wziąć pod uwagę przy ocenie procesu parowania.

Stopień zacienienia i ilość wody dostępnej na powierzchni są innymi czynnikami wpływającymi na proces parowania. Częste deszcze, nawadnianie i woda transportowana w górę gleby z płytkiego zwierciadła wód podziemnych zwilżają powierzchnię gleby. Tam, gdzie gleba jest w stanie dostarczyć wodę wystarczająco szybko, aby zaspokoić zapotrzebowanie na parowanie, parowanie z gleby zależy tylko od warunków meteorologicznych. Jednakże, gdy przerwa między opadami deszczu lub sztucznym nawadnianiem staje się duża, a zdolność gleby do przewodzenia wilgoci w pobliże powierzchni jest niewielka, zawartość wody w wierzchniej warstwie gleby spada, a powierzchnia gleby wysycha. W takich okolicznościach ograniczona dostępność wody wywiera kontrolujący wpływ na parowanie gleby. W przypadku braku jakiegokolwiek dopływu wody do powierzchni gleby, parowanie gwałtownie spada i może prawie całkowicie ustać w ciągu kilku dni.

Transpiracja polega na odparowaniu ciekłej wody zawartej w tkankach roślinnych i odprowadzeniu pary wodnej do atmosfery. Rośliny tracą wodę głównie przez aparaty szparkowe. Są to małe otwory na liściach roślin, przez które przechodzą gazy i para wodna. Woda, wraz z niektórymi składnikami odżywczymi, jest pobierana przez korzenie i transportowana przez roślinę. Parowanie zachodzi wewnątrz liścia, a mianowicie w przestrzeniach międzykomórkowych, a wymiana pary wodnej z atmosferą jest kontrolowana przez otwór szparkowy. Prawie cała pobrana woda jest tracona przez transpirację i tylko niewielka jej część jest wykorzystywana przez roślinę.

Transpiracja, podobnie jak parowanie bezpośrednie, zależy od dopływu energii, gradientu ciśnienia pary i wiatru. W związku z tym przy ocenie transpiracji należy wziąć pod uwagę promieniowanie, temperaturę powietrza, wilgotność powietrza i warunki wietrzne. Zawartość wody w glebie i zdolność gleby do przewodzenia wody do korzeni również determinują współczynnik transpiracji, podobnie jak podmokłość i zasolenie gleby. Na współczynnik transpiracji wpływają również cechy upraw, aspekty środowiskowe i praktyki uprawy. Różne rodzaje roślin mogą mieć różne współczynniki transpiracji. Przy ocenie transpiracji należy brać pod uwagę nie tylko rodzaj uprawy, ale także jej rozwój podczas sezonu wegetacyjnego, środowisko i zabiegi agrotechniczne.

Ewapotranspiracja jest zwykle wyrażana jako wysokość słupa odparowanej wody w jednostce czasu (np. mm/dzień). Można ją również wyrazić w jednostkach energii potrzebnej do przemiany fazowej, znanej jako utajone ciepło parowania (λ), które zależy od temperatury wody. Energia ta, określana wzorem $Q = m \cdot \lambda$, gdzie Q to energia (w dżulach), m to masa wody (w gramach), a λ to utajone ciepło parowania (w J/g), opisuje ilość energii niezbędnej do przekształcenia wody z cieczy w parę. Ze względu na zależność procesu ewapotranspiracji od wielu czynników środowiskowych, wprowadzono pojęcie ewapotranspiracji potencjalnej, zdefiniowanej jako „maksymalna szybkość parowania w danych warunkach środowiskowych, nieograniczona przez niedobór wody” (Novák, 2012) lub innymi słowami „maksymalna szybkość, z jaką atmosfera może pobrać wodę z powierzchni” (Hillel & Warrick, 2009). Szczególnym przykładem ewapotranspiracji potencjalnej jest ewapotranspiracja referencyjna zdefiniowana jako ewapotranspiracja z „doskonale uprawianych, dużych, dobrze nawodnionych pól, które osiągają pełną produkcję w danych warunkach klimatycznych” (Allen i in., 1998).

2.6.2. Pomiar ewapotranspiracji

Ze względu na złożoność procesu ewapotranspiracji, jej pomiar nie jest trywialny i często jest wieloetapowy zawierając elementy parametryzacji i szacowania.

Najprostszymi narzędziami pomiaru parowania są ewapometry. Pozwalają one na odczyt ubytku wody która została odparowana ze zbiornika. Należy jednak pamiętać, że metody te pozwalają na pomiar tylko parowania potencjalnego w sztucznych warunkach urządzenia, a więc nie uwzględniają one transpiracji, rodzaju powierzchni parowania oraz niedoborów wody. W celu oszacowania aktualnej (rzeczywistej) ewapotranspiracji, odczyty z tych urządzeń skalowane są empirycznymi współczynnikami zależnymi od rodzaju roślin i warunków meteorologicznych, takich jak prędkość wiatru i wilgotność (Abtew & Melesse, 2013).

Konstrukcjami pozwalającymi na bardziej bezpośredni pomiar ewapotranspiracji są lizymetry. Umożliwiają one na obserwację bilansu wodnego niewielkiego obszaru wpływając przy tym w nieznacznym stopniu na jego fizyczne i klimatyczne warunki. W większości przypadków główną częścią lizymetru jest zbiornik wypełniony glebą, w którym sadzi się roślinność. Aby móc na bieżąco mierzyć zmiany wilgotności, zbiornik jest umieszczony na wadze. Zakłada się, że zmiany wilgotności są związane ze zmianą masy zbiornika.. Lizymetry dostarczają dokładnych obserwacji dzięki czemu były wykorzystywane np. do kalibracji modeli ewapotranspiracji. Niemniej ze względu na koszty utrzymania, nie są one wykorzystywane do ciągłych, długookresowych pomiarów (Abtew & Melesse, 2013; Żurek, 2024).

Metodą pozwalającą na pomiar pionowych strumieni masy pary wodnej jest kowariancja wirów. Podstawą działania metody jest fakt, że w przypadku turbulentnego ruchu powietrza wartość kowariancji pomiędzy pionową składową prędkości wiatru i wilgotnością właściwą może być interpretowana jako pionowy strumień masy pary wodnej (Abtew & Melesse, 2013; Aubinet i in., 2012; Gu i in., 2012). Fluktuacje turbulentne zachodzą bardzo szybko, więc aparatura pomiarowa musi być wystarczająco zawansowana, aby pomiary prędkości wiatru i wilgotności powietrza były wykonywane z odpowiednio dużą częstotliwością rzędu 20 Hz (Foken, 2017).

Założeniem poprawnego pomiaru metodą kowariancji wirów jest występowanie turbulentnego ruchu powietrza. Turbulencja, która jest wynikiem ścinania przepływu powietrza oraz chwiejności atmosfery, jest rozpraszana w obrębie warstwy przyziemnej, gdzie większe wiry są rozdrabniane na mniejsze, aż do poziomu tarcia. Tego rodzaju procesy są bardziej intensywne podczas dnia, szczególnie przy silnym nasłonecznieniu, kiedy nagrzewanie powierzchni Ziemi prowadzi do rozwoju konwekcji i intensywnych turbulencji. Jednakże, w

nocy warunki te często nie są spełnione. Słabe wiatry i stabilna stratyfikacja atmosfery ograniczają rozwój turbulencji. Brak silnych procesów konwekcyjnych powoduje, że turbulencje mogą być niewystarczające do zapewnienia odpowiedniego poziomu wymiany gazów i energii między powierzchnią a atmosferą. W takich warunkach pomiary strumieni przy użyciu metody kowariancji wirów mogą być zafałszowane lub obarczone dużą niepewnością. Dodatkowo, metoda ta zakłada stan ustalony, co oznacza, że uśrednione w czasie pola wielkości opisujących stan atmosfery (np. prędkość wiatru, temperatura) nie powinny zmieniać się gwałtownie, ale zmieniać się w wolnym tempie. Kolejnym istotnym założeniem jest jednorodność pól w poziomie. Założenie to ma na celu wyeliminowanie wpływu zmiennych warunków meteorologicznych na pomiary. Zaniedbanie dywergencji strumieni turbulentnych, czyli brak zmienności z wysokością, również jest ważnym warunkiem, który powinien być spełniony. Oznacza to, że strumienie turbulentne w pionie nie zmieniają się znacząco na wysokości, na której dokonuje się pomiarów. Ponadto, teren wokół wieży pomiarowej powinien być homogeniczny i płaski, co minimalizuje wpływ zróżnicowanego terenu na wyniki pomiarów. (Aubinet i in., 2012; Burba & Anderson, 2010).

2.6.3. Teledetekcyjne szacowanie ewapotranspiracji

Teledetekcja umożliwia pozyskanie kluczowych parametrów, takich jak temperatura powierzchni ziemi, wilgotność gleby czy indeksy wegetacyjne, które są niezbędne do modelowania procesu ewapotranspiracji. Na podstawie tych danych możliwe jest zastosowanie różnych modeli do szacowania ET, które mogą być oparte na bilansie energetycznym, korelacjach empirycznych lub modelach hybrydowych.

Jednym z najczęściej stosowanych podejść do szacowania ewapotranspiracji przy użyciu danych teledetekcyjnych są modele oparte na bilansie energetycznym. Równanie bilansu energii można zapisać jako:

$$R_n - G = H + LE, \quad (2.6.3.1)$$

gdzie:

R_n – różnicowy strumień radiacji, czyli różnica pomiędzy promieniowaniem elektromagnetycznym absorbowanym i emitowanym przez powierzchnię,

G – strumień energii cieplnej do kolumny glebowej,

H – strumień energii cieplnej w postaci konwekcji (ciepło jawne),

LE – strumień energii związany z ewapotranspiracją (ciepło utajone).

Modele takie, jak Surface Energy Balance Algorithm for Land (SEBAL) i Mapping Evapotranspiration at High Resolution with Internalized Calibration (METRIC), wykorzystują dane teledetekcyjne do obliczenia bilansu energetycznego na powierzchni ziemi, a następnie szacują ET jako różnicę pomiędzy energią dostarczaną a energią rozpraszaną. W modelu SEBAL, ET jest obliczana na podstawie pomiaru promieniowania słonecznego, temperatury powierzchni oraz różnych współczynników takich jak albedo i współczynnik roślinności (Bastiaanssen i in., 1998). METRIC rozszerza ten model, wprowadzając wewnętrzną kalibrację na podstawie lokalnych danych meteorologicznych i danych z czujników naziemnych (Allen i in., 2007).

Kolejną grupą modeli stosowanych w teledetekcji ewapotranspiracji są modele empiryczne i półempiryczne. Te modele wykorzystują związki statystyczne między zmiennymi obserwowalnymi z przestrzeni kosmicznej (np. indeksy wegetacyjne) a ET. Jednym z powszechnie stosowanych wskaźników wegetacyjnych jest Normalized Difference Vegetation Index (NDVI), który jest używany do oszacowania gęstości roślinności, a tym samym potencjalnej ewapotranspiracji. Badania wykazały, że istnieje silna korelacja między NDVI a ET w różnych strefach klimatycznych i typach użytkowania ziemi (Glenn i in., 2008). W ramach modeli półempirycznych warto zwrócić uwagę na model PT-JPL (Priestley-Taylor Jet Propulsion Laboratory), który jest szeroko stosowany w misji ECOSTRESS (Ecosystem Spaceborne Thermal Radiometer Experiment on Space Station). Model ten zostanie opisany w kolejnym podrozdziale.

Modele hybrydowe łączą podejścia oparte na bilansie energetycznym i modele empiryczne, aby zwiększyć dokładność szacowania ET. Przykładem może być model Satellite-Based Energy Balance (SEBS), który wykorzystuje kombinację danych teledetekcyjnych i parametrów meteorologicznych do szacowania strumieni energii oraz ET na dużych obszarach (Su, 2002).

Wykorzystanie modeli takich jak OSEB czy TSEB pozwala na bardziej precyzyjne szacowanie wymiany ciepła pomiędzy roślinami a atmosferą. Model TSEB, stosowany dla modelowania ewapotranspiracji w uprawach, charakteryzuje się łatwością parametryzacji oporów w transporcie ciepła oraz oddzielnym obliczaniem strumieni ciepła jawnego i utajonego dla gleby i roślinności (Hoffmann i in., 2016; Xia i in., 2016). Modele takie jak HRMET, które wykorzystują minimalne dane meteorologiczne, są stosunkowo łatwe w użyciu, jednak wymagają dalszej walidacji dla złożonych struktur roślinnych, takich jak drzewa (Park, 2018). Metody oparte na uczeniu maszynowym (UM) są obiecujące, jednak wymagają dużych zbiorów danych do trenowania i walidacji (Poblete i in., 2017). Inne podejścia, jak SEBAL czy

METRIC, minimalizują potrzebę kalibracji temperaturowej, lecz są podatne na błędy związane z subiektywnym wyborem gorących i zimnych pikseli, co może wpływać na dokładność szacunków ET (Brenner i in., 2017; Montibeller, 2017).

Teledetekcyjny pomiar ewapotranspiracji znajduje szerokie zastosowanie w rolnictwie precyzyjnym, zarządzaniu zasobami wodnymi oraz monitorowaniu susz i powodzi. Pozwala na ocenę zużycia wody przez rośliny na dużą skalę i pomaga w podejmowaniu decyzji dotyczących nawadniania, co jest kluczowe w regionach o ograniczonych zasobach wodnych.

Jednym z głównych wyzwań związanych z teledetekcyjnym pomiarem ET jest potrzeba dostępu do dokładnych danych meteorologicznych i parametrów powierzchniowych, takich jak albedo, emisyjność, pokrycie przez roślinność, temperatura powierzchni, wilgotność gleby, współczynnik przewodzenia ciepła, a także dane dotyczące struktury i rodzaju roślinności, takich jak wysokość roślin czy gęstość liści. Ponadto, różne czynniki atmosferyczne, takie jak chmury i wilgotność atmosferyczna, mogą wpływać na jakość danych teledetekcyjnych. Wykorzystanie multispektralnych i hyperspektralnych sensorów może częściowo rozwiązać te problemy, zapewniając dane o wyższej rozdzielczości przestrzennej i większej dokładności.

2.6.4. Model Priestley-Taylor Jet Propulsion Laboratory (PT-JPL)

Bazą dla modelu PT-JPL jest równanie Priestley-Taylora, które wywodzi się z bardziej ogólnego równania Penmanna-Monteitha. Równanie Priestley-Taylora zostało zaprojektowane do szacowania potencjalnej ewapotranspiracji w sytuacjach, gdy dostępność wody nie jest ograniczona. Model PT-JPL opiera się na zmodyfikowanej wersji równania Priestley-Taylora, które zostało rozszerzone o parametry związane z dostępnością wody i stanem roślinności, co pozwala na oszacowanie rzeczywistej ewapotranspiracji.

Model PT-JPL wykorzystuje zmodyfikowaną wersję równania Priestley-Taylora do obliczenia potencjalnej ewapotranspiracji (PET), bazując na równaniach bilansu radiacyjnego i uwzględniając lokalne warunki atmosferyczne. Wprowadza również wskaźnik dostępności wody, który modyfikuje PET w celu uzyskania rzeczywistej ewapotranspiracji. Wskaźnik ten jest obliczany na podstawie wilgotności gleby i stanu roślinności, które są estymowane przy użyciu danych teledetekcyjnych. Stan roślinności jest uwzględniany poprzez zastosowanie wskaźników wegetacyjnych, takich jak NDVI (Normalized Difference Vegetation Index) lub EVI (Enhanced Vegetation Index), które są obliczane na podstawie danych spektralnych zebranych przez satelity lub inne platformy teledetekcyjne. Ponadto, PT-JPL korzysta z danych teledetekcyjnych w zakresie termalnym, aby oszacować temperaturę powierzchni ziemi, co jest kluczowym parametrem w obliczeniach bilansu energetycznego (Fisher, 2018).

2.7. Uczenie maszynowe w hydrologii

2.7.1. Popularne zastosowania uczenia maszynowego w hydrologii

W ostatnich latach hydrologia, podobnie jak wiele innych dziedzin nauki, przeszła znaczące zmiany w podejściu do modelowania procesów naturalnych. Tradycyjnie stosowane modele fizyczne, oparte na wiedzy eksperckiej i zrozumieniu podstawowych praw fizyki, takich jak równania Naviera-Stokesa czy Darcy'ego, oferują wysokie możliwości interpretacyjne. Pozwalają one na zrozumienie procesów hydrologicznych poprzez rozwiązywanie równań opisujących przepływ wody, parowanie, infiltrację oraz inne kluczowe procesy hydrologiczne. Mimo ich licznych zalet, modele te mają swoje ograniczenia, zwłaszcza w kontekście modelowania złożonych zjawisk.

Modele fizyczne często zakładają pewne uproszczenia, takie jak jednorodność medium, liniowość procesów, czy statyczność parametrów, co w rzeczywistości rzadko ma miejsce. Na przykład, złożoność terenu, zmienność właściwości gleby, oraz niejednorodność opadów mogą znacząco wpłynąć na dokładność wyników uzyskiwanych z modeli fizycznych. Dlatego też, w miarę jak rosną zbiory danych i wzrastają możliwości obliczeniowe komputerów, badacze coraz częściej zwracają się ku metodom opartym na danych, w tym uczeniu maszynowemu (UM), które nie wymagają uprzednich założeń co do natury modelowanego procesu, a jedynie odpowiednio dużego zbioru danych treningowych.

Uczenie maszynowe w hydrologii wykorzystuje algorytmy, które uczą się wzorców i zależności w danych historycznych, aby przewidywać przyszłe zjawiska hydrologiczne. Przykłady popularnych algorytmów UM stosowanych w hydrologii to sieci neuronowe, drzewa decyzyjne, lasy losowe, metody ensemble oraz nowsze metody głębokiego uczenia, takie jak sieci splotowe (ang. Convolutional Neural Networks, CNN) i rekurencyjne sieci neuronowe (RNN). Algorytmy te, dzięki swojej elastyczności i zdolności do przetwarzania dużych ilości danych, są szczególnie przydatne w modelowaniu skomplikowanych procesów hydrologicznych, które są nieliniowe i dynamiczne w czasie.

Zastosowanie uczenia maszynowego w hydrologii jest zróżnicowane. W wielu badaniach wykorzystano te techniki do przewidywania przepływów rzecznych, identyfikacji okresów suszy, prognozowania powodzi, a także do modelowania jakości wód powierzchniowych i podziemnych (C. Shen, 2018). Na przykład, sieci neuronowe zostały skutecznie zastosowane do prognozowania dziennych przepływów wód, uwzględniając różnorodne dane wejściowe, takie jak opady, temperatura, wilgotność gleby oraz wskaźniki hydrologiczne. Badania wykazały, że modele oparte na UM mogą przewidywać przepływy rzeczne z dokładnością

porównywalną, a niekiedy nawet wyższą, niż tradycyjne modele hydrologiczne (Kratzert i in., 2019).

Warto również wspomnieć o hybrydowych modelach, które łączą zalety modeli fizycznych i opartych na danych. Takie podejście pozwala na wykorzystanie fizycznych zasad i ograniczeń jako ram, w których działa model oparty na danych, co z kolei poprawia jego dokładność i interpretowalność (Mosavi i in., 2018).

2.7.2. Przetwarzanie obrazów uczeniem maszynowym

W kontekście opisanych w poprzednich rozdziałach zagadnień związanych z danymi rastrowymi (fotogrametria, termografia, przestrzenne rozkłady ewapotranspiracji), przybliżone zostaną tutaj metody uczenia maszynowego, które można wykorzystać do ich przetwarzania.

Przetwarzanie obrazów z wykorzystaniem uczenia maszynowego zyskuje na popularności dzięki rozwojowi zaawansowanych algorytmów oraz wzrostowi mocy obliczeniowej. Uczenie maszynowe pozwala na automatyczną ekstrakcję cech, klasyfikację obrazów, segmentację oraz inne operacje, które w tradycyjnych metodach przetwarzania obrazów były trudne lub niemożliwe do zrealizowania. Kluczową rolę w tych zadaniach pełnią sieci neuronowe, takie jak autoenkodery i sieci splotowe.

Głębokie sieci neuronowe (ang. Deep Neural Networks, DNN), a w szczególności splotowe sieci neuronowe (ang. Convolutional Neural Networks, CNN), zrewolucjonizowały przetwarzanie obrazów. CNN są zaprojektowane w taki sposób, aby automatycznie identyfikować istotne cechy w obrazach, takie jak krawędzie, tekstury czy kształty, co jest niezwykle ważne dla rozpoznawania i klasyfikacji obrazów. Badania wykazały, że CNN osiągają znakomite wyniki w wielu zadaniach związanych z analizą obrazów, takich jak rozpoznawanie obiektów czy segmentacja semantyczna (Krizhevsky i in., 2012). Podstawą działania CNN są operacje splotu, które przekształcają obrazy wejściowe w zestawy cech poprzez zastosowanie filtrów. Każda warstwa sieci przekształca dane na wyższym poziomie abstrakcji, umożliwiając bardziej złożone i precyzyjne interpretacje.

Autoenkodery to specyficzny typ sieci neuronowej, który służy do redukcji wymiarów danych (kompresji) oraz ich rekonstrukcji. Składają się one z dwóch głównych elementów: enkodera i dekodera. Enkoder przekształca obraz wejściowy o dużej liczbie wymiarów w skompresowaną reprezentację o niższej liczbie wymiarów. W kontekście przetwarzania obrazów, enkoder uczy się odwzorowania wejściowych danych, takich jak piksele obrazu, na bardziej abstrakcyjne reprezentacje, które zachowują istotne cechy obrazu, redukując jednocześnie redundantne informacje (Goodfellow i in., 2016). Dekoder z kolei odwzorowuje

skompresowaną reprezentację z powrotem do pierwotnego formatu, rekonstruując obraz wyjściowy. Uczy się on odzyskiwania informacji z formatu zakodowanego przez enkoder, co pozwala na rekonstrukcję danych przy możliwie najmniejszej utracie jakości. W badaniach nad autoenkoderami wykazano ich efektywność w zadaniach takich jak usuwanie szumów (ang. denoising) oraz generowanie nowych obrazów o podobnych cechach do danych wejściowych (Vincent i in., 2008). Dzięki tym zdolnościom autoenkodery są powszechnie wykorzystywane w zadaniach związanych z przetwarzaniem obrazów i kompresją danych.

Segmentacja obrazów to proces dzielenia obrazu na mniejsze fragmenty (segmenty), które reprezentują różne obiekty lub obszary o podobnych cechach. Głębokie sieci neuronowe, takie jak sieci U-Net, są szeroko stosowane w zadaniach związanych z segmentacją medyczną oraz w innych obszarach, gdzie precyzyjne rozpoznawanie obiektów jest kluczowe (Ronneberger i in., 2015). Modele segmentacyjne mogą być trenowane na zestawach danych oznaczonych przez ekspertów, dzięki czemu sieć uczy się automatycznego przypisywania każdemu pikselowi w obrazie odpowiedniej klasy. W literaturze badawczej opisano liczne przypadki sukcesów takich metod, zwłaszcza w dziedzinie analizy obrazów medycznych (Çiçek i in., 2016).

3. Proponowane autorskie metody

3.1. Szacowanie poziomu wody małych strumieni przy pomocy fotogrametrii BSP i uczenia głębokiego.

Akwizycja danych

Dane fotogrametryczne i wzorcowe pomiary poziomu wody zebrano dla rzeki Kocinki – niewielkiej rzeki nizinnej (długość 40 km, powierzchnia zlewni 260 km²) położonej w dorzeczu Odry w południowej Polsce. Dane zebrano na dwóch odcinkach tej rzeki o podobnej charakterystyce hydromorfologicznej:

- Około 700-metrowy odcinek rzeki Kocinki zlokalizowany w pobliżu miejscowości Grodzisko (50.8744N, 18.9711E). Odcinek ten ma szerokość około 2 m. W bezpośrednim sąsiedztwie rzeki nie ma drzew. Dno zbudowane jest głównie z mułu. Brzegi i koryto rzeki porośnięte są roślinnością wystającą ponad powierzchnię wody. Brzegi są stromo nachylone pod kątem od około 50° do 90° w stosunku do powierzchni wody. W pobliżu znajdują się mokradła, do których miejscami wpływa woda rzeczna. Dane z tego odcinka zostały zebrane w następujących dniach:
 - 19 grudnia 2020 r. Podczas pomiarów występowało całkowite zachmurzenie. Ze względu na sezon zimowy roślinność była niewielka. Próbkę uzyskaną z tego badania oznaczono identyfikatorem „GRO20”.
 - 13 lipca 2021 r. Podczas pomiarów nie występowało zachmurzenie. Przybrzeżne rośliny były wysokie, a powierzchnia wody była gęsto porośnięta rzęsą wodną. Próbkę uzyskaną z tego badania oznaczono identyfikatorem „GRO21”.
- Około 700-metrowy odcinek rzeki Kocinki zlokalizowany w pobliżu miejscowości Rybna (50.9376N, 19.1143E). Odcinek ten ma szerokość około 3 m. Miejscami występują drzewa liściaste z koronami nachylonymi nad obszar rzeki. Koryto rzeki zbudowane jest z jasnego piasku widocznego przez przejrzystą wodę. Z koryta rzeki nie wyrasta żadna roślinność. Brzegi nachylone są pod kątem ok. 20° do 90° względem powierzchni wody. Dane z tego odcinka zostały zebrane w następujących dniach:
 - 19 grudnia 2020 r. Podczas pomiarów występowało całkowite zachmurzenie. Ze względu na sezon zimowy drzewa były pozbawione liści, a trawy były niskie. Próbkę uzyskaną z tego badania oznaczono identyfikatorem „RYB20”.
 - 13 lipca 2021 r. Podczas pomiarów nie było zachmurzenia. Trawy przybrzeżne były wysokie. Przy dobrym oświetleniu i wyjątkowo przejrzystej wodzie koryto

rzeki było wyraźnie widoczne przez wodę. Próbki uzyskane z tego badania oznaczono identyfikatorem „RYB21”.

Zestaw danych został uzupełniony o dane z badań przeprowadzonych przez Bandini i in. (2019) na około 2,3-kilometrowym odcinku rzeki Åmose Å (Dania) w dniu 21 listopada 2018 roku. Rzeka jest skanalizowana i dobrze utrzymana. Brzegi są porośnięte niską trawą, a sąsiednie nieliczne drzewa są pozbawione liści z powodu zimy. Bandini i in. (2020) opisują szczegóły dotyczące tego studium przypadku w swojej publikacji. W badaniu tym przetestowano najnowocześniejsze metody pomiaru poziomu wody w rzekach za pomocą BSP przy użyciu pomiarów radarowych, lidarowych i fotogrametrycznych. Dzięki temu uzyskany zestaw danych stanowi dobry punkt odniesienia do oceny dokładności nowej metody poprzez porównanie jej z istniejącymi metodami. Próbki uzyskane z tego badania są oznaczone w zestawie danych identyfikatorem „AMO18”.

Podczas kampanii badawczych przeprowadzono pomiary fotogrametryczne nad obszarem rzeki. Zdjęcia lotnicze wykonano z bezzałogowego statku powietrznego DJI S900 przy użyciu kamery Sony ILCE a6000 z obiektywem Voigtlander SUPER WIDE HELIAR VM 15 mm f/4.5. Wysokość lotu wynosiła około 77 m AGL, co dało piksel terenu o wielkości 20 mm. Pokrycie przednie wynosiło 80%, a boczne 60%.

Podczas lotów kamera była skierowana w stronę nadiru. Niektórzy badacze proponują przeprowadzenie wielu lotów na różnych wysokościach i wykorzystując różne kąty kierunkowania kamery. Taki zabieg ma na celu skuteczne uchwycenie obszarów przesłoniętych przez nachyloną roślinność lub stromy teren (Bandini i in., 2020). W przypadku badania będącego przedmiotem tej rozprawy nie wykorzystano tych technik, biorąc pod uwagę efektywność czasową i fakt, że podczas dalszej obróbki danych trójwymiarowy model fotogrametryczny jest przekształcany w jego dwuwymiarową reprezentację w postaci ortograficznego rastra NMPT, efektywnie prezentując widok wyłącznie z perspektywy nadiru.

Oprócz lotów dronem, naziemne punkty referencyjne zostały ustalone w całym obszarze zainteresowania przy użyciu odbiornika GNSS Leica GS 16 RTN. Wzorcowe pomiary poziomu wody w rzece zostały również wykonane przy użyciu tego samego odbiornika GNSS RTN. Pomiary przeprowadzono wzdłuż rzeki co około 10-20 metrów na obu brzegach.

Przetwarzanie danych

Pliki rastrowe ortofotomapy i NMPT zostały wygenerowane przy użyciu oprogramowania fotogrametrycznego Agisoft Metashape. Do osadzenia rastrów w geograficznym układzie odniesienia wykorzystano naziemne punkty referencyjne. Dalsze przetwarzanie danych zostało

przeprowadzone przy użyciu oprogramowania ArcGIS ArcMap. Każdy z uzyskanych w wyniku przetwarzania fotogrametrycznego rastrów miał szerokość i wysokość kilkudziesięciu tysięcy pikseli i reprezentował część zlewni o powierzchni przekraczającej 30 ha. Na potrzeby rozwiązania uczenia maszynowego próbki reprezentujące obszary terenu o wymiarach 10 m × 10 m zostały ręcznie wyodrębnione z wielkoskalowych rastrów ortofotomapy i NMPT. Każda próbka zawiera obszar wody i przyległy grunt. Próbki nie nakładają się na siebie.

Punktowe pomiary poziomu wody zostały interpolowane przy użyciu regresji wielomianowej w funkcji odległości wzdłuż linii środkowej rzeki. W sytuacji, gdy tama bobrowa spowodowała gwałtowną zmianę poziomu powierzchni wody, regresje wykonano oddzielnie dla odcinków przed i za tamą. Wartości poziomów wody interpolowane regresją zostały przypisane do próbek rastrowych zgodnie z lokalizacją geoprzestrzenną. Średnie wartości poziomu wody z segmentu linii środkowej rzeki znajdującego się w obszarze próbki zostały przypisane do próbki jako rzeczywisty poziom wody. Standard Error of Estimate (Siegel, 2016) został użyty do określenia dokładności danych wzorcowych. Został on obliczony przy użyciu wzoru:

$$S_e = \sqrt{\frac{1}{n-2} \sum_{i=1}^n (WSE_i - \widehat{WSE}_i)^2}, \quad (3.1.1)$$

gdzie:

n – numer punktu pomiaru poziomu wody,

WSE_i – zmierzony poziom wody,

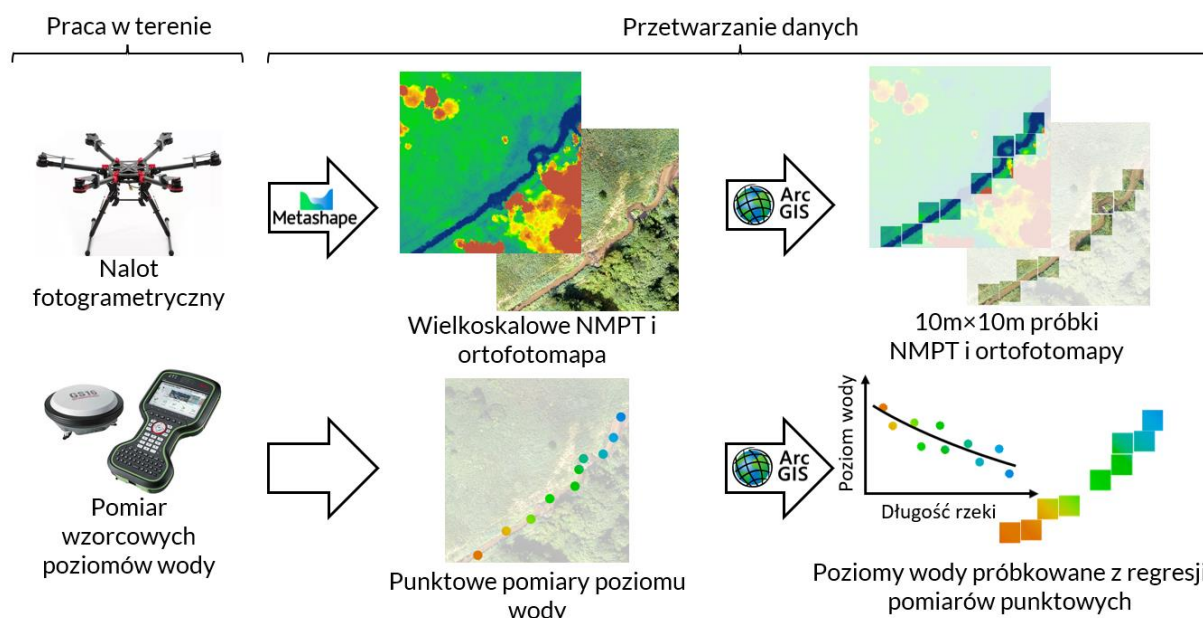
\widehat{WSE}_i – poziom wody odczytany z krzywej regresji.

Wyniki badania Standard Error of Estimate znajdują się w tab. 3.1.1. Widzimy, że błąd dla pomiarów wzorcowych wynosi maksymalnie 2 cm.

Tab. 3.1.1. Liczba pomiarów punktowych poziomu wody, Standard Error of Estimate dla wartości poziomu wody interpolowanych regresją i liczba wyodrębnionych rastrowych próbek dla każdego studium przypadku (Szostak i in., 2024).

Podzbiór	Liczba punktowych pomiarów poziomu wody	Standard Error of Estimate dla wartości interpolowanych regresją (m)	Liczba rastrowych próbek w zbiorze danych
GRO21	36	0.012	64
RYB21	52	0.013	55
GRO20	84	0.020	72
RYB20	76	0.016	57
AMO18	7235	0.020	74

Rys. 3.1.1 przedstawia schemat opisanego powyżej procesu przygotowania zbioru danych uczenia maszynowego zarówno podczas pracy w terenie, jak i podczas przetwarzania danych.



Rys. 3.1.1. Proces przygotowania zbioru danych uczenia maszynowego (Szostak i in., 2024).


Struktura zbioru danych uczenia maszynowego

Zbiór danych uczenia maszynowego składa się z 322 próbek. Szczegółowe informacje na temat liczby próbek w każdym podzbiorniku można znaleźć w tab. 3.1.1. Każda próbka zawiera następujące dane:

- **Ortofotomapa.** Kwadratowy wycinek ortofotomapy reprezentujący obszar 10 m × 10 m, zawierający rzekę i sąsiadujący grunt. Obraz w skali szarości reprezentowany jako tablica 256×256 wartości całkowitych o wartościach od 0 do 255 (1-kanalowy obraz 256×256 pikseli).

- NMPT. Kwadratowy wycinek NMPT reprezentujący ten sam obszar, co próbka ortofotomapy opisana powyżej. Przechowywany jako tablica 256×256 liczb zmiennoprzecinkowych zawierających wysokości pikseli wyrażone w m n.p.m.
- Poziom wody. Średni poziom wody odcinka rzeki zawartego w próbkach ortofotomapy i NMPT. Reprezentowany jako pojedyncza wartość zmiennoprzecinkowa wyrażona w m n.p.m.
- Metadane. Dla każdej próbki przechowywane są następujące dodatkowe informacje:
 - Średnia, odchylenie standardowe, minimalne i maksymalne wartości fotogrametrycznej tablicy próbek NMPT. Mogą być wykorzystane do standaryzacji lub normalizacji. Reprezentowane jako wartości zmiennoprzecinkowe wyrażone w m n.p.m.
 - Szerokość i długość geograficzna. Współrzędne geograficzne środka próbki w układzie WGS-84. Reprezentowane jako liczby zmiennoprzecinkowe.
 - Odległość od początku odcinka rzeki. Wyrażona w metrach odległość od początku odcinka rzeki mierzona wzdłuż wyznaczonej manualnie linii środka rzeki.
 - Nazwa podzbioru. Wartość tekstowa identyfikująca podzbiór, do którego należy próbka. Dostępne wartości: „GRO21”, „RYB21”, „GRO20”, „RYB20”, „AMO18”.


Przykłady rastrowych próbek ortofotomapy i NMPT przedstawiono na rys. 3.1.2. Należy pamiętać, że w ostatecznym rozwiązaniu próbki ortofotomapy zredukowane są do skali odcieni szarości.



Rys. 3.1.2. Przykłady próbek rastrowych ze zbioru danych uczenia maszynowego dla poszczególnych podzbiorów. Ortofotomapy przedstawione są w górnym , a odpowiadające im NMPT (m n.p.m.) przedstawione są w dolnym rzędzie (Szostak i in., 2024).

Odwzorowanie powierzchni wody na NMPT

Rys. 3.1.3 przedstawia przykładowe rastrowe próbki zbioru danych z zaznaczonymi obszarami, w których NMPT jest równy rzeczywistemu poziomowi wody z marginesem błędu ± 5 cm. Można zauważyć, że obszary w których NMPT odzwierciedla poziom wody są nieregularne i wzorce ich występowania nie są łatwe do zdefiniowania. W wielu przypadkach nie spełniona jest zasada mówiąca, że poziom wody odczytany z NMPT przy brzegu rzeki odpowiada rzeczywistemu poziomowi wody.




Rys. 3.1.3. Przykładowe próbki rastrowe NMPT i ortofotomapy z zaznaczonymi obszarami, w których NMPT jest równy rzeczywistemu poziomowi wody ± 5 cm (kolor czerwony) (Szostak i in., 2024).

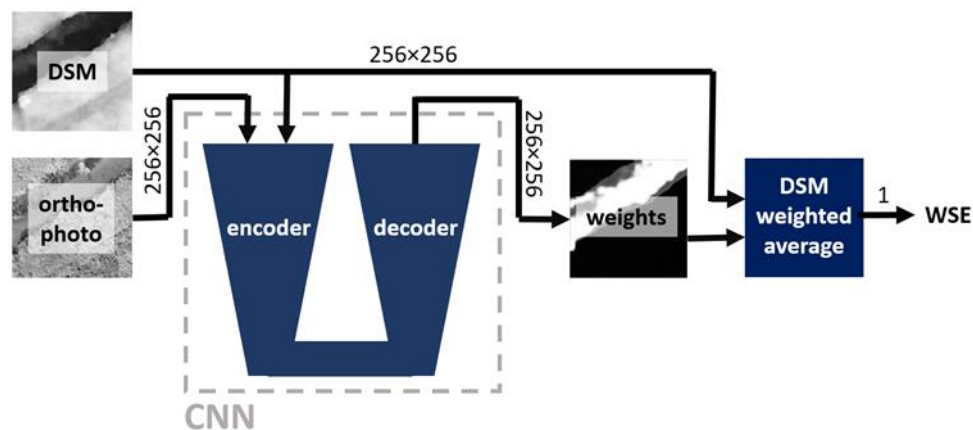
Architektury uczenia głębokiego

W badaniu będącym przedmiotem tej rozprawy do oszacowania poziomu wody w rzece na podstawie NMPT i ortofotomapy wykorzystano splotową (konwolucyjną) sieć neuronową. Przetestowane zostały dwa podejścia: bezpośrednia regresja poziomu wody przy użyciu

enkodera i rozwiązanie oparte na średniej ważonej NMPT z wykorzystaniem maski wag przewidywanej przez sieć typu autoenkoder. Zaproponowane podejścia będą określane w dalszej części rozprawy jako "regresja bezpośrednia", "uśrednianie maską". Rysunki 3.1.4 i 3.1.5 przedstawiają schematyczne reprezentacje zaproponowanych podejść.



Rys. 3.1.4. Schemat metody regresji bezpośredniej. Liczby obok strzałek oznaczają wymiary macierzy przepływających danych (Szostak i in., 2024).



Rys. 3.1.5. Schemat metody uśredniania maską. Liczby obok strzałek oznaczają wymiary macierzy przepływających danych (Szostak i in., 2024).

Wszystkie modele CNN wykorzystane w tym badaniu zostały skonfigurowane tak, aby przyjmowały na wejściu dwukanałowe obrazy składające się z kanału NMPT i ortofotomapy w skali szarości. We wszystkich podejściach trening jest przeprowadzany z użyciem funkcji straty błędu średniokwadratowego (MSE). Oznacza to, że w podejściu uśredniania maską do treningu nie wykorzystano wzorcowych masek, tak jak to zazwyczaj ma miejsce podczas treningu autoenkoderów np. w zastosowaniach semantycznej segmentacji. Zamiast tego rozwiązanie samodzielnie uczy się określać optymalną maskę wag poprzez minimalizację funkcji straty MSE.

Do generowania masek wag wykorzystano architektury CNN pierwotnie zaprojektowane do semantycznej segmentacji. Dzięki zastosowaniu sigmoidalnej funkcji aktywacji na wyjściu modelu, generuje on maski wagowe o wartościach w zakresie od 0 do 1. Wszystkie architektury

wykorzystane w tym badaniu pochodziły z biblioteki Segmentation Models Pytorch (Iakubovskii, 2019).

Wszystkie treningi przeprowadzono przy pomocy optymalizatora Adam ze współczynnikiem uczenia (ang. learning rate) wynoszącym 10^{-5} . Treningi były prowadzone do momentu, gdy wartość RMSE na podzbiorze walidacyjnym nie wykazywała dalszej redukcji przez kolejne 20 epok uczenia. Biorąc pod uwagę, że wielkość bloku danych (ang. batch size) ma znaczący wpływ na dokładność, różne jego wartości zostały przetestowane podczas poszukiwania optymalnej konfiguracji.

Skalowanie danych

Ponieważ tablice NMPT i ortofotomap mają wartości z różnych zakresów i rozkładów, są one poddawane skalowaniu przed wprowadzeniem ich do modelu uczenia głębokiego. Ma to na celu zapewnienie właściwej zbieżności optymalizacji metodą gradientów (Wan, 2019). Wartości NMPT zostały znormalizowane zgodnie z równaniem:

$$NMPT' = \frac{NMPT - \overline{NMPT}}{2\sigma}, \quad (3.1.2)$$

gdzie:

$NMPT'$ – znormalizowana próbka rastra NMPT,

$NMPT$ – oryginalna próbka rastra NMPT,

\overline{NMPT} – średnia wartość oryginalnej próbki rastra NMPT,

$\sigma = 1.197$ [m] – odchylenie standardowe wartości próbek NMPT z całego zbioru danych.

Ta metoda standaryzacji ma dwie zalety. Po pierwsze, odejmując średnią wartość próbki, zapewnia się wyśrodkowanie wokół zera znormalizowanych NMPT, dzięki czemu algorytm jest niewrażliwy na bezwzględne różnice wysokości między rzekami z różnych podzbiorów. Informacje o rzeczywistym poziomie wody nie są tracone, ponieważ mogą być odzyskane po predykcji algorytmem uczenia maszynowego poprzez odwrotną normalizację. Po drugie, podzielenie wszystkich próbek przez tę samą wartość σ zapewnia, że wszystkie znormalizowane próbki są przeskalowane jednakowo. Podczas wstępnych testów modelu eksperymentalnie stwierdzono, że pomnożenie mianownika przez 2 skutkuje lepszą dokładnością modelu w porównaniu do standaryzacji, która nie uwzględnia tego czynnika.

Próbki ortofotomap zostały znormalizowane przy użyciu średniej i odchylenia standardowego zestawu danych ImageNet (Deng i in., 2009) zgodnie z równaniem:

$$ORT' = \frac{ORT - \mu}{\sigma}, \quad (3.1.3)$$

gdzie:

ORT' – znormalizowana próbka ortofotomapy,

ORT – oryginalna próbka ortofotomapy,

$\mu = 0.449$ – średnia z wartości próbek ze zbioru ImageNet. Została obliczona jako średnia trzech wartości odpowiadającym kanałom zielonemu, czerwonemu i niebieskiemu (0.485, 0.456, 0.406),

$\sigma = 0.226$ – średnie odchylenie standardowe próbek ze zbioru ImageNet. Zostały obliczone jako średnia odchyłeń standardowych odpowiadających kanałom zielonemu, czerwonemu i niebieskiemu (0.229, 0.224, 0.225).


Augmentacja zbioru danych

W celu zwiększenia rozmiaru zbioru danych trenujących, a tym samym poprawy uogólnienia predykcji, każda tablica próbek używana do trenowania modelu została poddana następującym operacjom augmentacji: i) obrót o 0° , 90° , 180° lub 270° , ii) brak inwersji, inwersja w osi x, inwersja w osi y lub inwersja zarówno w osi x, jak i y. Daje to łącznie 16 permutacji, co sprawia, że zestaw danych treningowych jest 16 razy większy.

Walidacja krzyżowa

W celu znalezienia optymalnej konfiguracji zastosowano dwie odmiany metod k-krotnej walidacji krzyżowej: *stratified* i *all-in-case-out*.

W wariacie *stratified*, zbiór danych został podzielony na 5 podzbiorów, z których każdy zawierał porównywalną ilość próbek z każdego studium przypadku (GRO21, RYB21, GRO20, RYB20, AMO18). Podział został zrealizowany poprzez wybór co piątej próbki z całego zbioru danych. Proces ten zwizualizowano na rys. 3.1.6.



Rys. 3.1.6. Wybór próbek walidacyjnych dla każdego z 5 podzbiorów w walidacji krzyżowej typu *stratified* (Szostak i in., 2024).

W wariancie *all-in-case-out* również utworzono 5 podzbiorów. Jednak w tym scenariuszu każdy podzbiór walidacyjny zawierał próbki wyłącznie z jednego studium przypadku, a pozostałe próbki z pozostałych 4 studiów przypadku zostały wykorzystane do trenowania modelu. Ta metoda walidacji krzyżowej ocenia zdolność modelu do generalizacji, tj. zdolności do formułowania predykcji na podstawie danych spoza rozkładu danych treningowych.

Poszukiwanie optymalnej konfiguracji (grid search)

Poszukiwanie najlepszej konfiguracji proponowanych rozwiązań przeprowadzono przy użyciu metody *grid search*, cechującej się tym, że testowane są wszystkie możliwe kombinacje proponowanych wartości hiperparametrów. Propozycje wartości hiperparametrów zależały od wariantu podejścia (regresja bezpośrednia lub uśrednianie maską). Kombinacje hiperparametrów obejmowały różne typy enkoderów, architektur i wielkości bloków danych. Przetestowano następujące architektury autoenkoder: U-Net (Ronneberger i in., 2015), MA-Net (Fan i in., 2020) i PSP-Net (Zhao i in., 2016). Testowanymi enkoderami były różne głębokości enkoderów VGG (Simonyan & Zisserman, 2015) i ResNet (He i in., 2015). Szczegóły dotyczące konfiguracji stosowanych dla każdego podejścia przedstawiono w tab. 3.1.2.

Tab. 3.1.2. Propozycje architektury, kodera i wielkości bloków danych używane w wyszukiwaniu siatki (Szostak i in., 2024).

Podejście	Architektury	Enkodery	Rozmiary bloków danych
Regresja bezpośrednia	-	ResNet18, ResNet50, VGG11, VGG13, VGG16, VGG19	1, 2, 4, 8, 16
Uśrednianie maską	U-Net, MA-Net, PSP-Net	VGG13, VGG16, VGG19	1, 2, 4, 8, 16

Określanie dokładności bazowej

Aby możliwe było ilościowe określenie wartości dodanej przez rozwiązanie uczenia maszynowego, przed rozpoczęciem eksperymentu zdefiniowano dokładność bazową (ang. *baseline accuracy*). Jest to miara, która reprezentuje minimalny poziom dokładności, jaki model predykcyjny powinien osiągnąć, aby być uznanym za lepszy niż najprostsza metoda przewidywania. W eksperymentach uczenia maszynowego zazwyczaj dokładność bazowa odnosi się do dokładności osiągananej przez model, który stosuje najprostsze reguły, np. przewiduje zawsze najczęściej występującą klasę (dla klasyfikacji) lub średnią wartość (dla regresji).

W przypadku tego eksperymentu dokładność bazową wyliczono używając wartości poziomu wody uzyskanych przy pomocy bezpośredniego próbkowania rastra NMPT wzdłuż krzywej biegnącej przez środek rzeki i krzywej wytyczonej przy brzegu strumienia (Bandini i in., 2020). Odczyty te zostaną wykorzystane do porównania z proponowaną metodą opartą na uczeniu głębokim. Krzywe wzdłuż których próbkowane były rastry zostały wyznaczone ręcznie, bez użycia jakiegokolwiek algorytmu. Wyznaczanie tych krzywych przeprowadzone było z zachowaniem ostrożności, zwłaszcza w metodzie próbkowania wzdłuż brzegu, kiedy zwracano uwagę na to, aby próbki były konsekwentnie pobierane z obszaru wody, ale możliwie blisko brzegu strumienia.

3.2. Automatyczna kalibracja lotniczych obrazów termowizyjnych przy użyciu optymalizacji metodą gradientów

Akwizycja danych

Zdjęcia termowizyjne zostały zebrane za pomocą BSP DJI Matrice 300 RTK wyposażonego w wieloczuJNIKOWY system Zenmuse H20T, zawierający niechłodzoną mikrobolometryczną kamerę termowizyjną. Zdjęcia wykonano z wysokości 50 m przy poziomie przekrycia 80% zarówno bocznym jak i frontalnym. Dane zostały zebrane z trzech obszarów w południowej Polsce:

- odcinek strumienia Kocinka o długości około 500 m w pobliżu wsi Grodzisko (50.8715 N, 18.9661 E);
- odcinek strumienia Kocinka o długości około 350 m w pobliżu wsi Rybna (50.9371 N, 19.1134 E);
- odcinek potoku Sudół o długości około 160 m w pobliżu Krakowa (50.0999 N, 19.9027 E).

Temperatura wody w rzekach była mierzona za pomocą termopary wzdłuż ich biegu. Wyniki były stałe na całych odcinkach. Tab. 3.2.1 zawiera szczegółowe informacje na temat lokalizacji, dat, warunków badań i zmierzonych temperatur wody w rzekach.

Tab. 3.2.1. Informacje na temat podzbiorów danych (Szostak i in., 2023).

Oznaczenie	Lokacja	Czas	Warunki	Temperatura wody
A	Kocinka, Rybna	15.12.2021 12:20	Mgła, pokrywa śnieżna	4.6 °C
B	Kocinka, Rybna	18.01.2022 14:55	Pokrywa śnieżna, całkowite zachmurzenie	2.6 °C
C	Kocinka, Rybna	25.03.2022 07:30	Brak zachmurzenia	5.6 °C
D	Sudół, Kraków	20.12.2022 11:20	Średnie zachmurzenie	2.0 °C
E	Kocinka, Grodzisko	11.01.2023 11:00	Brak zachmurzenia	4.2 °C

Korekcja efektu winiety

Korekcja efektu winiety została przeprowadzona przy użyciu metody *single image* (Yuanjie Zheng i in., 2009). Algorytm typu *single image* to taki algorytm przetwarzania obrazu, który operuje na pojedynczym zdjęciu, bez odniesienia do dodatkowych obrazów lub informacji. W kontekście korekcji efektu winiety oznacza to, że algorytm bazuje wyłącznie na danych z tego jednego zdjęcia i próbuje oszacować, które części obrazu są ciemniejsze ze względu na winietę, a które mają inne przyczyny takiego wyglądu. Ponieważ nie ma dostępu do dodatkowych informacji (np. innego zdjęcia bez winiety, czy danych o rzeczywistym oświetleniu sceny), algorytm może źle ocenić, co faktycznie jest wynikiem winiety, a co naturalnym efektem oświetlenia lub sceny.

Na potrzeby tego eksperymentu, implementacja autorów algorytmu w języku MATLAB dostępna pod adresem https://github.com/GUOYI1/Vignetting_corrector (dostęp 18 czerwca 2023 r.) została przetłumaczona na język Python. Wprowadzono kilka zmian w celu dostosowania algorytmu do pracy z obrazami termowizyjnymi. Standardowe obrazy są reprezentowane za pomocą wartości zmiennoprzecinkowych od 0 do 1 lub liczb całkowitych od 0 do 255. Oryginalna implementacja algorytmu zakładała ten format danych, więc musiała zostać zmodyfikowana, aby działała na nieograniczonych wartościach zmiennoprzecinkowych przechowujących wartości temperatur. Zmierzone temperatury mogą być również ujemne. Algorytm korekcji efektu winiety operuje na logarytmach wartości pikseli, więc temperatury zostały przekonwertowane na Kelwiny, aby uniknąć logarytmu z 0. Algorytm korekcji winietowania ma tendencję do zwiększania jasności zdjęcia. W przypadku standardowych zdjęć nie stanowi to problemu, ale w przypadku obrazów termowizyjnych, zwiększenie jasności

efektywnie spowoduje zwiększenie zmierzonej temperatury, co może prowadzić do przekłamanych pomiarów. Założono, że obrazy termiczne zawierają dokładniejsze temperatury w ich centralnej części, gdzie efekt winiety jest mniej widoczny. Dlatego centralna część zdjęcia przed korekcją została wykorzystana jako poziom odniesienia dla zdjęcia uzyskanego po zastosowaniu algorytmu korekcji efektu winiety. Odchylenie jest kompensowane przez odjęcie średniej różnicy między centralnymi obszarami obrazów przed i po korekcji winiety. Rozmiar centralnego obszaru odniesienia jest definiowany jako prostokąt o bokach dwa razy krótszych od odpowiadających boków przetwarzanego obrazu.

Georeferencja

Algorytm georeferencji jest w dużej mierze oparty na rozwiązaniu łączenia zdjęć lotniczych zaproponowanego przez Luna Yue Huang (Huang, 2020). W zaproponowanej metodzie dokonano zmian polegających na bezpośredniej georeferencji do uniwersalnego poprzecznego układu współrzędnych Merkatora UTM (ang. Universal Transverse Mercator). Należy pamiętać, że jest to georeferencja przybliżona, ponieważ nie jest możliwe dokładne georeferencjonowanie pojedynczego zdjęcia przedstawiającego widok nieortograficzny. Mimo wszystko, poniższa metoda georeferencjonowania okazała się wystarczająco dokładna dla proponowanej metody kalibracji temperatury.


Pierwszą częścią procedury georeferencji jest wstępna georeferencja obrazów na podstawie metadanych EXIF. Zawierają one informacje o współrzędnych geograficznych, pochyleniu i wysokości kamery BSP w momencie wykonania zdjęcia. Informacje te, wraz z kątem pola widzenia odczytanym ze specyfikacji kamery, pozwalają na oszacowanie parametrów przekształcenia afinicznego translacji (v_x , v_y), skali (s_x , s_y) i obrotu w kierunku przeciwnym do ruchu wskazówek zegara (θ), co pozwala na osadzenie obrazu w układzie współrzędnych UTM. Nie jest to dokładne szacowanie ze względu na niską dokładność lokalizacji GPS i wysoką wrażliwość na przesunięcie obszaru widzenia kamery pod wpływem podmuchów wiatru. Parametry skali s_x i s_y są sobie równe, a współczynniki ścinania (c_x , c_y) wynoszą 0. Wyzerowanie parametrów ścinania z procedury było możliwe, ponieważ kamera jest wyposażona w system gimbała kontrolujący położenie kamery podczas lotu w pozycji nadir. Parametry transformacji pozwalają na stworzenie macierzy transformacji A na podstawie równania:

$$\begin{aligned}
A &= \begin{pmatrix} \cos \theta & -\sin \theta & v_x \\ \sin \theta & \cos \theta & v_y \\ 0 & 0 & 1 \end{pmatrix} \cdot \begin{pmatrix} s_x & c_x & 0 \\ c_y & s_y & 0 \\ 0 & 0 & 1 \end{pmatrix} \\
&= \begin{pmatrix} s_x \cos \theta - c_y \sin \theta & c_x \cos \theta - s_y \sin \theta & v_x \\ c_y \cos \theta + s_x \sin \theta & s_y \cos \theta - c_x \sin \theta & v_y \\ 0 & 0 & 1 \end{pmatrix}
\end{aligned} \tag{3.2.1}$$

W oparciu o wstępną georeferencję znajdowane są pary potencjalnie przekrywających się obrazów. Aby zapewnić znalezienie wszystkich możliwych par, nawet jeśli w wyniku błędu w początkowej georeferencji rejestrowane obszary zdjęć się nie nakładają, są one rozszerzane przez operację dylatacji. Każda para obrazów jest dopasowana przy pomocy następujących kroków: (i) znajdowanie punktów charakterystycznych na obu obrazach za pomocą algorytmu SIFT (ang. scale-invariant feature transform) (Lowe, 2004), (ii) dopasowywanie punktów charakterystycznych za pomocą algorytmu FANN (ang. fast approximate nearest neighbour) (Muja & Lowe, 2009) oraz (iii) oszacowanie najlepszej macierzy transformacji za pomocą algorytmu RANSAC (ang. random sample consensus) (Fischler & Bolles, 1981). Rezultatem dopasowania jest względna macierz transformacji A_R definiująca położenie drugiego zdjęcia w układzie odniesienia pierwszego zdjęcia z pary. Czasami na podstawie błędnie zinterpretowanych punktów charakterystycznych dopasowane są ze sobą zdjęcia, które w rzeczywistości się nie przekrywają. Aby wykryć niepoprawne dopasowania, względne transformacje są weryfikowane w dwóch etapach: (i) ponieważ zakładamy, że obrazy są wykonane z tej samej wysokości (badane obszary są płaskie), współczynnik skalowania we względnej transformacji dwóch nakładających się obrazów musi być w przybliżeniu równy 1. Jeśli wartość współczynnika skalowania dla względnych transformacji wykracza poza zakres 0,9-1,1, względna transformacja jest uważana za nieprawidłową. (ii) Ponieważ wszystkie obrazy są wykonywane w orientacji nadir (dzięki systemowi gimbała), przekształcenia względne nie powinny wykonywać operacji ścinania. Gdy nie występuje ścinanie, wartości bezwzględne macierzy transformacji względnej A_R spełniają następujący warunek: $|A_{R11}| = |A_{R22}|$ i $|A_{R12}| = |A_{R21}|$. Jeśli odchylenie między tymi wartościami jest większe niż 0,1, względna transformacja jest uważana za nieprawidłową. Jeśli względna transformacja okaże się niepoprawna, podejmowana jest próba ustalenia względnej transformacji przy użyciu tej samej pary obrazów, ale w dwukrotnie mniejszej rozdzielczości. Jeśli względna transformacja uzyskana za pomocą tej procedury również nie przejdzie weryfikacji, analizowana para obrazów jest odrzucana.

Na podstawie zweryfikowanych par przekrywających się obrazów konstruowany jest graf nieukierunkowany, w którym wierzchołki odpowiadają zdjęciom lotniczym, a krawędzie są

transformacjami względnymi między parami obrazów (rys. 3.2.1). Następnie z grafu wyodrębniane są spójne składowe. Spójna składowa grafu to grupa wierzchołków, które są ze sobą bezpośrednio lub pośrednio połączone. Tylko obrazy (wierzchołki) ze spójnej składowej grafu zawierającej największą liczbę wierzchołków są używane do dalszego przetwarzania.



Rys. 3.2.1. Przykładowy graf zdjęć lotniczych z pozycjami wierzchołków odpowiadającymi lokalizacji geograficznej zdjęć. Zielonym kolorem oznaczono spójną składową grafu zawierającą największą liczbę wierzchołków (Szostak i in., 2023).

Współrzędne dowolnego punktu drugiego obrazu w parze mogą być wyrażone w układzie współrzędnych pierwszego obrazu w parze przy użyciu macierzy transformacji względnej A_R :

$$p_I = A_R \cdot p_{II} \quad (3.2.2)$$


gdzie:

A_R – względna macierz transformacji między układami współrzędnych drugiego i pierwszego obrazu w parze,

p_{II} – współrzędne punktu drugiego obrazu wyrażone w układzie współrzędnych drugiego obrazu,

p_I – współrzędne tego samego punktu wyrażone w układzie współrzędnych pierwszego obrazu.

Przy pomocy powyższego równania, dla każdej zweryfikowanej pary dopasowanych zdjęć, znajdowane są współrzędne narożników drugiego zdjęcia wyrażone w układzie współrzędnych pierwszego zdjęcia. Zamysł tej procedury jest przedstawiony na rys. 3.2.2.



Rys. 3.2.2. Wizualizacja procedury dopasowania przykładowej pary obrazów o wymiarach 640×512 pikseli. Współrzędne zaznaczonych narożników są wyrażone w układzie współrzędnych pierwszego obrazu (Szostak i in., 2023).

Optymalizacja georeferencji wszystkich obrazów uzyskanych podczas lotu polega na dostrojeniu bezwzględnych parametrów transformacji geograficznej (v_x , v_y , s_x , s_y , θ) dla wszystkich obrazów jednocześnie, w taki sposób, aby względne transformacje pomiędzy parami zdjęć uzyskane podczas optymalizacji były jak najbardziej zbliżone do względnych transformacji uzyskanych wcześniej przy użyciu dopasowania każdej pary osobno. Odzyskanie zoptymalizowanej macierzy transformacji względnej \widehat{A}_R ze zoptymalizowanych macierzy absolutnej transformacji geograficznej \widehat{A}_I i \widehat{A}_{II} dwóch obrazów uzyskuje się zgodnie z równaniem:

$$\widehat{A}_R = \widehat{A}_I^{-1} \cdot \widehat{A}_{II} \quad (3.2.3)$$

Parametry ścinania c_x i c_y nie są dostrajane podczas optymalizacji. Chociaż dostrojenie tych parametrów poprawia dopasowanie między parami zdjęć, wprowadza również niedopuszczalne ścinanie całej mozaiki zdjęć.

Podobnie jak w równaniu 3.2.2, współrzędne punktów wyrażone w układzie odniesienia drugiego zdjęcia można przekonwertować na współrzędne wyrażone w układzie odniesienia pierwszego zdjęcia za pomocą równania:

$$\widehat{p}_I = \widehat{A}_R \cdot p_{II} \quad (3.2.4)$$

gdzie:

\widehat{A}_R – względna macierz transformacji między układami współrzędnych drugiego i pierwszego obrazu w parze po optymalizacji georeferencji;

p_{II} – współrzędne punktu drugiego obrazu wyrażone w układzie odniesienia drugiego obrazu;

\widehat{p}_I – współrzędne tego samego punktu wyrażone w układzie odniesienia pierwszego obrazu po optymalizacji georeferencji.

Optymalizacja georeferencji jest przeprowadzana przy użyciu metody gradientów z funkcją straty L , która składa się z dwóch komponentów \mathcal{L}_R i \mathcal{L}_A . Składnik \mathcal{L}_R to średnia odległość euklidesowa między współrzędnymi punktów narożnych uzyskanymi z transformacji względnej odzyskanej z dostrojonej absolutnej transformacji geograficznej a współrzędnymi odpowiadających im punktów, które zostały uzyskane z transformacji względnej podczas dopasowania każdej pary zdjęć osobno. Sposób obliczenia składnika \mathcal{L}_R przedstawiono równaniem:

$$\mathcal{L}_R = \frac{1}{N_P} \sum_{i=1}^{N_P} \frac{1}{4} \sum_{j=1}^4 \|p_{I,i,j} - \widehat{p}_{I,i,j}\| \quad (3.2.5)$$

gdzie:

N_P – liczba par zdjęć;

$p_{I,i,j}$ – współrzędne j -ego narożnika drugiego zdjęcia z i -tej pary zdjęć wyrażone w układzie odniesienia pierwszego zdjęcia uzyskane z dopasowania każdej pary zdjęć oddzielnie;

$\widehat{p}_{I,i,j}$ – współrzędne j -ego narożnika drugiego zdjęcia z i -tej pary zdjęć wyrażone w układzie odniesienia pierwszego zdjęcia uzyskane z macierzy przekształcenia dostrojonej metodą gradientów.

Komponent \mathcal{L}_A to średnia odległość euklidesowa między geograficznymi położeniami środków obrazów o skalibrowanej georeferencji, a geograficznymi położeniami środków obrazów uzyskanymi podczas wstępnego georeferencjonowania przy użyciu danych EXIF:

$$\mathcal{L}_A = \frac{1}{N_I} \sum_{i=1}^{N_I} \|p_i - \widehat{p}_i\| \quad (3.2.6)$$

gdzie:

N_I – liczba obrazów;

p_i – współrzędne środka i -tego obrazu uzyskanego w wyniku wstępnej georeferencji z danych EXIF;

\widehat{p}_i – współrzędne środka i -tego obrazu uzyskanego z georeferencji dostrojonej podczas optymalizacji.


Minimalizując współczynnik \mathcal{L}_R bezwzględne przekształcenia geograficzne są dostrajane tak, aby względne przekształcenia między parami obrazów, które zostały z nich odzyskane, były jak najbardziej zbliżone do względnych przekształceń uzyskanych wcześniej osobno dla każdej pary. Minimalizacja współczynnika \mathcal{L}_A zapewnia, że cała mozaika nie przesunie się podczas optymalizacji. Równanie 3.2.7 jest ostateczną formułą dla funkcji straty \mathcal{L} . Aby zmniejszyć wpływ na względne dopasowanie obrazów przy użyciu komponentu \mathcal{L}_R mniej

ważny składnik \mathcal{L}_A jest mnożony przez współczynnik 10^{-6} . Wartość współczynnika została wybrana eksperymentalnie poprzez jakościową ocenę wyników testowanych dla różnych wartości.

$$\mathcal{L} = \mathcal{L}_R + 10^{-6} \mathcal{L}_A \quad (3.2.7)$$


Kalibracja różnic temperatury

Aby użyć metody gradientów do zminimalizowania różnic temperatur między przekrywającymi się obrazami, należy przygotować spójny zestaw danych. Jeśli redukcja efektu winietowania nie przyniosła wystarczających rezultatów, a nakładanie się zdjęć jest wystarczająco duże, obszary zdjęć w pobliżu krawędzi, w których efekt winietowania najbardziej wpływa na obrazy temperatury, mogą zostać obcięte (rys. 3.2.3).



Rys. 3.2.3. Przykład wykluczenia obszarów przy krawędziach obrazów w celu redukcji wpływu efektu winiety na kalibrację (Szostak i in., 2023).

Dla każdej pary obrazów zachowywana jest tylko część wspólna, a także maska, która pozwala odtworzyć nieregularny kształt wycięcia z reprezentacji zdjęcia będącego prostokątną tablicą liczb. Wycięcia części wspólnych obrazów i maska są przeskalowywane i rozciągane aby zajęły cały obszar tablicy o wymiarach 32×32 pikseli. Podczas zmiany rozmiaru temperatury są interpolowane przy użyciu metody dwuliniowej, a maska jest interpolowana przy użyciu metody najbliższych sąsiadów. Przykładowe wycinki części wspólnych obrazów i odpowiadającą im maskę przedstawiono na rys. 3.2.4. Przykład odpowiada parze obrazów pokazanej na rysunkach 2 i 3. Obrót wynika z transformacji do bezwzględnego geograficznego układu odniesienia. Brak zachowania proporcji wynika z potrzeby skalowania w celu wypełnienia całego obszaru kwadratowej tablicy pikseli. 32×32 pikseli.



Rys. 3.2.4. Przykładowe wycinki części wspólnych pary przekrywających się obrazów przeskalowane do macierzy 32×32 pikseli (b, c) i odpowiadająca im binarna maska (a) (Szostak i in., 2023).

Dzięki przeskalowaniu rozmiaru wycinków do 32×32 pikseli, możliwe było utworzenie spójnego zbioru danych składającego się z trzech tablic (maski i dwóch wycinków dla pary obrazów) o rozmiarach $N_p \times 32 \times 32$, gdzie N_p to liczba par przekrywających się obrazów.

Optymalizacja wartości temperatury obejmuje dostrojenie pojedynczej wartości przesunięcia b między skalibrowanym i nieskalibrowanym obrazem:

$$\hat{v} = v + b \quad (3.2.8)$$

gdzie:

\hat{v} – wartość temperatury z zastosowaną kalibracją;

v – wartość temperatury przed kalibracją.

Optymalizacja temperatury wykorzystuje funkcję straty \mathcal{L} która składa się z dwóch składników: \mathcal{L}_B i \mathcal{L}_M . Składnik \mathcal{L}_B to błąd średniokwadratowy między skalibrowanymi wartościami temperatury pierwszego i drugiego wyciętego obrazu z danej pary:

$$\mathcal{L}_B = \frac{1}{N_p} \sum_{i=1}^{N_p} \frac{1}{32} \sum_{j=1}^{32} \frac{1}{32} \sum_{k=1}^{32} (v_{1st,l,j,k} - v_{2nd,l,j,k})^2 \quad (3.2.9)$$

gdzie:

N_p – liczba par;

$v_{1st,l,j,k}$ – skalibrowana wartość temperatury piksela o współrzędnych (j,k) pierwszego obrazu w i-tej parze;

$v_{2nd,l,j,k}$ – skalibrowana wartość temperatury piksela o współrzędnych (j,k) drugiego obrazu w i-tej parze.

\mathcal{L}_M to wartość bezwzględna różnicy między średnimi wartościami temperatur z nieskalibrowanych i skalibrowanych obrazów:

$$\mathcal{L}_M = |\mu - \hat{\mu}| \quad (3.2.10)$$

gdzie:

μ – średnia temperatura ze wszystkich nieskalibrowanych obrazów,

$\hat{\mu}$ – średnia temperatura ze wszystkich skalibrowanych obrazów.

Minimalizując składnik \mathcal{L}_B minimalizowana jest różnica między wartościami temperatury przekrywających się części obrazów. Składowa \mathcal{L}_M zapewnia, że podczas optymalizacji cała mozaika nie będzie dryfować od początkowej średniej wartości temperatury. Ostateczna funkcja straty obliczana jest przy użyciu równania 3.2.11. Aby zminimalizować wpływ \mathcal{L}_M na korekcję temperatur przy użyciu składnika \mathcal{L}_B składnik \mathcal{L}_M został pomnożony przez współczynnik 10^{-2} . Wartość współczynnika została wybrana eksperymentalnie poprzez jakościową ocenę wyników testowanych dla różnych wartości.

$$\mathcal{L} = \mathcal{L}_B + 10^{-2}\mathcal{L}_M \quad (3.2.11)$$

Opcjonalna kalibracja względem pomiarów referencyjnych

Minimalizacja różnic temperatury pomiędzy przekrywającymi się częściami zdjęć termowizyjnych przyczynia się do zwiększenia precyzji pomiaru temperatury. Wciąż jednak może wystąpić błąd systematyczny o stałej wartości dla wszystkich zdjęć. Można go skompensować poprzez użycie pomiarów referencyjnych wykonanych w terenie np. metodami in-situ.

W przypadku tego badania wykorzystano pomiary temperatury rzeki jako wartości referencyjne. Rzeki na badanych obszarach mają stałe temperatury na całych badanych odcinkach. Temperatury obrazów zostały przesunięte o taką samą wartość dla wszystkich obrazów, tak aby średnia temperatura z całej długości rzeki odczytana z mozaiki zdjęć termicznych była równa zmierzonej średniej referencyjnej temperaturze wody. Taka metoda korekcji jest opcjonalna, jednak wykonanie jej jest łatwe i może pozytywnie przyczynić się do zmniejszenia błędu pomiaru temperatury. W kontekście ewaluacji zaproponowanej metody kalibracji wykorzystującej metodę gradientów, korekcja błędu systematycznego ułatwia porównanie precyzji pomiaru przed i po procedurze kalibracji.

3.3. Szacowanie ewapotranspiracji na podstawie termografii BSP

Mozaiki termiczne sporządzone ze zdjęć termowizyjnych wykonanych z pokładu BSP mogą zostać wykorzystane do szacowania ewapotranspiracji. W ramach pracy doktorskiej będącej przedmiotem tej rozprawy zaadaptowano do pracy z danymi BSP algorytm PT-JPL (Fisher, 2018) wykorzystywany do szacowań ewapotranspiracji w satelitarnej misji ECOSTRESS.

Akwizycja danych

Dane potrzebne do wykonania eksperymentu zebrano na kampanii pomiarowej przeprowadzonej w dniach 7-9 lipca 2023 nad rzeką Kocinka na wysokości wsi Grodzisko (50.8681 N, 18.9555 E). Przez cały czas pomiarów panowała bezchmurna pogoda z

temperaturami powietrza oscylującymi pomiędzy minimum 13 °C w nocy, a maksimum 30 °C w dzień. Do pomiarów wykorzystano BSP zbierającego geoprzestrzenne dane rastrowe oraz stacjonarną wieżę z oprzyrządowaniem do pomiaru różnego rodzaju pomiarów punktowych.

Modelem BSP użytym do pomiarów był DJI Matrice 300 RTK. Zdjęcia zbierane przy jego pomocy obejmowały obszar o wymiarach ok. 240 m × 270 m. Zebrano zarówno zdjęcia termowizyjne jak i multispektralne.

Zdjęcia multispektralne zostały wykonane przy pomocy kamery Micasense RedEdge-MX dnia 8 lipca o godzinie 12:00. Panowała wtedy bezchmurna pogoda. Wykonanie pomiarów w południe było celowym zabiegiem minimalizacji wpływu cieni obiektów na pomiary. W wyniku pomiarów uzyskano obrazy z pasm światła niebieskiego (475 nm ± 20 nm), zielonego (560 nm ± 20 nm), czerwonego (668 nm ± 10 nm), *red edge* (717 nm ± 10 nm) oraz bliskiej podczerwieni (840 nm ± 40 nm). Uzyskany rozmiar piksela obrazów multispektralnych wynosił 7 cm. Frontalne przekrycie zdjęć wynosiło 80%, a boczne 70%.

Zdjęcia termowizyjne wykonano przy użyciu kamery DJI Zenmuse H20T. Łącznie wykonano 12 lotów pomiarowych. Dаты i godziny akwizycji zdjęć termicznych przedstawiono w tab. 3.3.1. Uzyskany rozmiar piksela obrazów termowizyjnych wynosił 9 cm. Frontalne przekrycie zdjęć wynosiło 80%, a boczne 70%.

Tab. 3.3.1. Dаты i godziny akwizycji zdjęć termowizyjnych.

Data	Godzina
Piątek, 7 lipca 2023	19:59
Sobota, 8 lipca 2023	0:09, 3:12, 5:10, 8:02, 12:11, 16:06, 19:54, 23:36
Niedziela, 9 lipca 2023	3:54, 8:18, 11:28

W środku obszaru fotografowanego przy użyciu BSP umieszczono wieżę zaopatrzoną w zestaw urządzeń zbierających dane meteorologiczne, radiacyjne i glebowe potrzebne zarówno do metody kowariancji wirów, jak i adaptacji PT-JPL. Użyte czujniki przedstawiono w tab. 3.3.2. Zdjęcie wieży przedstawiono na rys. 3.3.1.

Tab. 3.3.2. Czujniki zamontowane na wieży.

Nazwa	Opis
LI-COR SmartFlux	rejestrator danych dla kowariancji wirów
LI-COR LI-7500DS	analizator CO ₂ i H ₂ O z otwartą ścieżką pomiarową
Gill WindMaster	wiatromierz ultradźwiękowy
HongYuv WDC6SE	kompaktowa stacja meteorologiczna
Campbell Scientific CR310	rejestrator danych
Apogee Instruments SN-500	bilansomierz radiacyjny
METER TEROS 12	czujnik wilgotności i temperatury gleby
Hukseflux HFP01-05	czujnik strumienia ciepła glebowego
Apogee SQ-110	czujnik strumienia promieniowania w zakresie asymilacji



Rys. 3.3.1. Wieża z oprzyrządowaniem pomiarowym.

Kowariancja wirów

W badaniu wykonano pomiary strumienia metodą kowariancji wirów, które przeprowadzono w sposób ciągły od godziny 17:30 UTC dnia 7 lipca (piątek) do godziny 11:30 UTC dnia 9 lipca (niedziela). Uzyskane dane zostały uśrednione do półgodzinnych przedziałów czasowych. W sumie uzyskano 83 wyniki pomiarów strumieni.

Punkt pomiarowy stacji kowariancji wirów znajduje się w obszarze traw o wysokości 10 cm, gdzie dominuje trawa, oraz 13 m od pola uprawnego, gdzie rośnie owies. Szorstkość terenu

określono na 7,5 cm. Pomiary są wykonywane na wysokości 3,5 metra. Odległość między analizatorem Li-7500DS a wiatromierzem WindMaster w kierunkach Wschód, Północ, oraz Zachód wynosi odpowiednio 0 cm, -23 cm i 0 cm. Promień izolinii 99% zasięgu bilansomierza wynosi 35 m.

PT-JPL

Algorytm PT-JPL (Priestley-Taylor Jet Propulsion Laboratory) (Fisher, 2018) jest oparty o równanie Priestleya-Taylora (Priestley & Taylor, 1972) na ewapotranspirację potencjalną, będące zredukowaną wersją równania Penmana-Monteitha (Allen i in., 1998). Wzór Priestleya-Taylora jest następujący:

$$PET = \alpha \frac{\Delta}{\Delta + \gamma} R_n, \quad (3.3.1)$$

gdzie:

PET – ewapotranspiracja potencjalna,

$\alpha = 1.26$,

Δ – nachylenie krzywej prężności pary wodnej nasyconej w danej temperaturze,

γ – stała psychrometryczna,

R_n – różnicowy strumień radiacji.

Aby zredukować PET do rzeczywistej ET (AET), gdy ograniczona jest dostępność wody, wprowadzono ekofizjologiczne funkcje ograniczeń, mające bezwymiarowe wartości z zakresu od 0 do 1. Funkcje te oparte są na wilgotności atmosferycznej i wskaźnikach wegetacji.

W tab. 3.3.3 przedstawiono wartości mierzone w terenie, wykorzystane do obliczenia ewapotranspiracji metodą PT-JPL zaadaptowaną dla danych z BSP. W tabeli x przedstawiono wzory użyte do obliczeń funkcji ograniczeń i innych wielkości wykorzystywanych w adaptacji algorytmu PT-JPL dla danych z BSP. Dodatkowe wyjaśnienia zawarto w tekście poniżej tabel.

Tab. 3.3.3. Wartości mierzone w terenie wykorzystane do obliczenia ewapotranspiracji metodą PT-JPL zaadaptowaną dla danych BSP.

Nazwa	Symbol	Jednostka	Urządzenie	Uwagi
temperatura powietrza	T_a	°C	HongYuv WDC6SE	Pomiar ciągły, punktowy.
ciśnienie atmosferyczne	p_a	Pa	HongYuv WDC6SE	Pomiar ciągły, punktowy.
promieniowanie krótkofalowe przychodzące	$R_{s,in}$	W/m ²	Apogee Instruments SN-500	Pomiar ciągły, punktowy.
promieniowanie krótkofalowe wychodzące	$R_{s,out}$	W/m ²	Apogee Instruments SN-500	Pomiar ciągły, punktowy. Opcjonalny. Wykorzystany do oszacowania albedo.
promieniowanie długofalowe przychodzące	$R_{l,in}$	W/m ²	Apogee Instruments SN-500	Pomiar ciągły, punktowy.
promieniowanie długofalowe wychodzące	$R_{l,out}$	W/m ²	Apogee Instruments SN-500	Pomiar ciągły, punktowy. Opcjonalny. Wykorzystany do oszacowania współczynnika emisyjności.
względna wilgotność powietrza	RH	-	HongYuv WDC6SE	Pomiar ciągły, punktowy.
zdjęcia multispektralne	RED, NIR	-	MicaSense RedEdge-MX	Pomiar jednorazowy, rastrowy.
zdjęcia termowizyjne	LST	°C	DJI Zenmuse H20T	Pomiar ciągły (co ok. 3 godziny), rastrowy.
temperatura gleby	T_G	°C	METER TEROS 12	Pomiar ciągły, punktowy

Tab. 3.3.4. Wzory użyte do obliczenia ewapotranspiracji zaadaptowaną metodą PT. Gdzie nie znaleziono odpowiednika nazwy wielkości w języku polskim użyto angielskiego odpowiednika.

Nazwa	Wzór	Źródło
albedo krótkofalowe powierzchni	$A = \overline{R_{s,out}}/\overline{R_{s,in}}$	(Fisher, 2018)
współczynnik emisyjności	$\varepsilon = \operatorname{argmin}_{\varepsilon} \left \left(\frac{R_{l,out,night}}{\sigma \varepsilon} \right)^{\frac{1}{4}} - 273.15 - T_{G,night} \right $	Prawo Stefana-Boltzmann
współczynnik Priesleya-Taylora	$\alpha = 1.26$	(Fisher i in., 2008)
prężność pary wodnej nasyconej	$e_s = 610.8 \cdot e^{17.27 \cdot T_a / (T_a + 237.3)}$	(Allen i in., 1998)
nachylenie krzywej prężności pary wodnej nasyconej	$\Delta = 4098 \cdot \frac{e_s}{(T_a + 237.3)^2}$	(Allen i in., 1998)
stała psychrometryczna	$\gamma = 0.000665 \cdot p_a$	(Allen i in., 1998)
znormalizowany różnicowy wskaźnik wegetacji	$NDVI = (NIR - RED)/(NIR + RED)$	(Boehmer, 1996)
soil-adjusted vegetation index	$SAVI = \frac{NIR - RED}{NIR + RED + 0.5} \cdot (1 + 0.5)$	(Boehmer, 1996)
leaf area index	$LAI = \frac{\ln \frac{0.69 - SAVI}{0.59}}{0.91}$	(Allen i in., 2007)
deficyt ciśnienia par	$VPD = e_s \cdot (1 - RH)$	(Allen i in., 1998)
względna wilgotność powierzchni	$f_{wet} = RH^4$	(Fisher i in., 2008)
soil moisture constraint	$f_{SM} = RH^{VPD}$	(Fisher, 2018)
fraction of absorbed photosynthetically active radiation	$f_{APAR} = 1.2 \cdot 1.136 \cdot SAVI + (1.2 \cdot (-0.04))$	(Fisher i in., 2008)
fraction of intercepted photosynthetically active radiation	$f_{IPAR} = 1.0 \cdot NDVI - 0.05$	(Fisher i in., 2008)
green canopy fraction	$f_g = \frac{f_{APAR}}{f_{IPAR}}$	(Fisher, 2018)
promieniowanie krótkofalowe wychodzące	$R_{s,out} = A \cdot R_{s,in}$	(Fisher, 2018)
promieniowanie długofalowe wychodzące	$R_{l,out} = \sigma \cdot \varepsilon \cdot (LST + 273.15)^4$ gdzie σ to stała Stefana-Boltzmann	Prawo Stefana-Boltzmann, (Fisher, 2018)
Różnicowy strumień radiacji	$R_n = R_{s,in} - R_{s,out} + R_{l,in} - R_{l,out}$	(Fisher, 2018)
różnicowy strumień radiacji dla gleby	$R_{ns} = R_n \cdot e^{-0.6 \cdot LAI}$	(Fisher i in., 2008)
Różnicowy strumień radiacji dla roślin	$R_{nc} = R_n - R_{ns}$	(Fisher i in., 2008)

Obliczanie rzeczywistej ewapotranspiracji w algorytmie PT-JPL realizowane jest poprzez zsumowanie obliczonych oddzielnie ewapotranspiracji z gruntu (ET_s), z roślin (ET_c) oraz wody przechwyconej z opadu przez np. rośliny (ET_i). Przyczynek ET_s obliczany jest następująco:

$$ET_s = (f_{wet} + f_{SM} \cdot (1 - f_{wet})) \cdot \alpha \cdot \frac{\Delta}{\Delta + \gamma} \cdot (R_{ns} - G) \quad (3.3.2)$$

Przyczynek ET_c obliczany jest następująco:

$$ET_c = (1 - f_{wet}) \cdot f_g \cdot f_m \cdot f_t \cdot \alpha \cdot \frac{\Delta}{\Delta + \gamma} \cdot R_{nc} \quad (3.3.3)$$

Przyczynek ET_i obliczany jest następująco:

$$ET_i = f_{wet} \cdot \alpha \cdot \frac{\Delta}{\Delta + \gamma} \cdot R_{nc} \quad (3.3.4)$$

Ostateczna formuła na rzeczywistą ewapotranspirację jest następująca:

$$AET = ET_s + ET_c + ET_i \quad (3.3.5)$$

Tabele 3.3.3 oraz 3.3.4 pozwalają na odtworzenie procesu obliczania ewapotranspiracji. Miejscami przydatny może być jednak dodatkowy komentarz. Albedo wyrażone wzorem $A = \overline{R_{s,out}} / \overline{R_{s,in}}$ oszacowane jest z definicji. Jako, że dysponowaliśmy serią pomiarów radiacji krótkofalowych użyto średnich. Współczynnik emisyjności wyrażony wzorem $\varepsilon = \operatorname{argmin}_{\varepsilon} \left| \left(\frac{R_{l,out,night}}{\sigma \varepsilon} \right)^{\frac{1}{4}} - 273.15 - T_{G,night} \right|$ jest wartością emisyjności dla której temperatura gleby pod wieżą obliczona z prawa Stefana-Boltzmann'a z użyciem zmierzonej emitowanej radiacji długofalowej jest najbardziej zbliżona do temperatury zmierzonej przez czujnik umieszczony w glebie. Wybrano wartości mierzone w nocy, ponieważ pod nieobecność promieni słonecznych temperatura gleby na głębokości płytki wyrównuje się z temperaturą powierzchni ziemi emitującej mierzone promieniowanie.

Lotnicze zdjęcia termowizyjne zostały poddane kalibracji opisanej w rozdziale 3.2. Uzasadnione jest to zjawiskiem szczególnie widocznym podczas nocnych zdjęć, gdy temperatury powietrza spadały do kilku °C i wychłodzona kamera ulegała znaczącym dryfom pomiarowym na początku lotów. Wykorzystano tylko kalibrację minimalizującą różnicę między przekrywającymi się zdjęciami, a z redukcji efektu winiety zrezygnowano. Rezygnacja z redukcji efektu winiety motywowana jest tym, że jest to algorytm typu „single image”, więc jest podatny na błędne interpretacje (szczegóły na ten temat w rozdziale 3.2, sekcja „korekcja efektu winiety”). Następnie ze skalibrowanych zdjęć wykonano termiczne ortofotomapy przy

pomocy oprogramowania fotogrametrycznego, które niweluje efekty winiety dzięki uśrednianiu pikseli należących do wielu zdjęć.


Pomiary ewapotranspiracji uzyskane metodą kowariancji wirów charakteryzowały się półgodzinnym okresem uśredniania. Mozaiki termowizyjne powierzchni obszaru zainteresowania mierzone były z okresem około 3 godzin. Aby dopasować rozdzielczość czasową mozaik temperaturowych do pomiarów z wieży, dokonano interpolacji czasowej mozaik temperaturowych. Proces ten rozpoczęto poprzez ujednoczenie rozdzielczości i dopasowanie pikseli wszystkich rastrów termowizyjnych. W wyniku tego procesu uzyskano macierz trójwymiarową o wymiarach *wysokość rastra × szerokość rastra × ilość lotów pomiarowych*. Interpolację wykonano przy pomocy wielu funkcji kwadratowych tzw. metodą splines. Interpolowano osobno każdy piksel wzdłuż wymiaru czasu. W efekcie, z 12 rastrów temperatury powierzchni obszaru zainteresowania zbieranych z okresem ok. 3 godzin, uzyskano zinterpolowane 86 rastrów z 30-minutowym okresem. Pomiary meteorologiczne z wieży zapisywane były z okresem 1 minuty. Uśredniono je dla półgodzinnych okresów odpowiadających rezultatom uzyskanym metodą kowariancji wirów. Dzięki doprowadzeniu wszystkich danych do wspólnej częstotliwości próbkowania, możliwe było porównanie metody PT-JPL z kowariancją wirów.

4. Dyskusja wyników


4.1. Wyniki szacowania poziomu wody małych strumieni przy pomocy fotogrametrii BSP i uczenia głębokiego.

Wyniki poszukiwania optymalnej konfiguracji

W celu znalezienia optymalnej konfiguracji modelu przeprowadzono wiele treningów, używając różnych hiperparametrów i podzbiorów walidacyjnych. Szczegółowe statystyki wyników wyszukiwania przedstawiono na rysunkach 4.1.1 - 4.1.5.




Rys. 4.1.1. Regresja bezpośrednia – wyniki RMSE walidacji uzyskane dla różnych enkoderów i podzbiorów walidacji krzyżowej. Słupki błędów, wskazujące 95% przedziały ufności, wynikają z różnych wielkości bloków danych testowanych podczas eksperymentów (Szostak i in., 2024).




Rys. 4.1.2. Regresja bezpośrednia – wyniki RMSE walidacji uzyskane dla różnych wielkości bloków danych i podzbiorów walidacji krzyżowej. Słupki błędów, wskazujące 95% przedziały ufności, wynikają z różnych enkoderów testowanych podczas eksperymentów (Szostak i in., 2024).

W przypadku metody regresji bezpośredniej, dla większości podzbiorów walidacji krzyżowej enkodery typu VGG wyróżniają się lepszą dokładnością w porównaniu do enkoderów ResNet (rys. 4.1.1). Można zaobserwować pewien wpływ rozmiaru bloków danych na dokładność, jako że dokładność dla rozmiaru bloków danych równego 1 jest zauważalnie gorsza niż dla pozostałych rozmiarów bloków danych. Należy jednak zwrócić uwagę, że

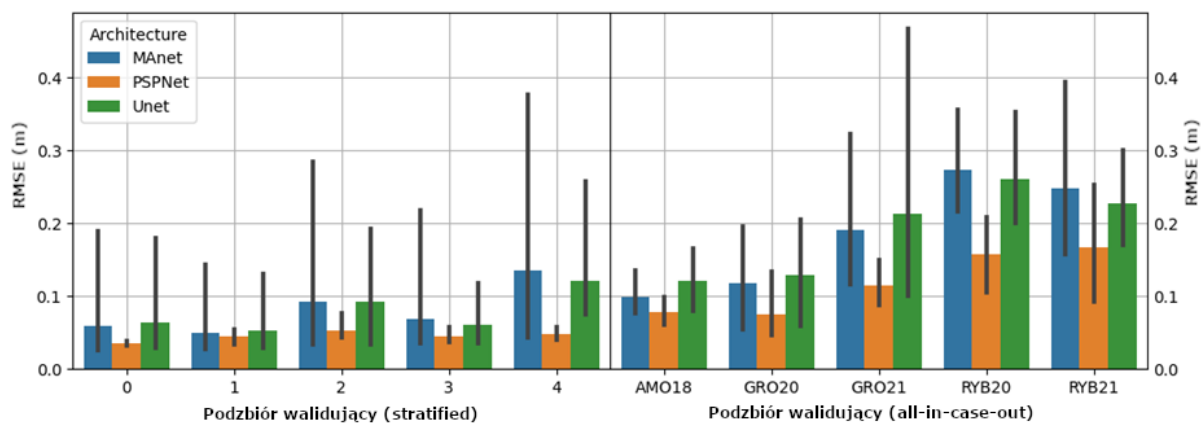
przedział ufności dla rozmiaru bloków danych równego 1 jest znacząco większy, więc pojedyncze związane z nim testy mogły osiągnąć dokładność porównywalną z najlepszymi (rys. 4.1.2).



Rys. 4.1.3. Uśrednianie maską – wyniki RMSE walidacji uzyskane dla różnych enkoderów i podzbiorów walidacji krzyżowej. Słupki błędów, wskazujące 95% przedziały ufności, wynikają z różnych wielkości bloków danych i architektur testowanych podczas eksperymentów (Szostak i in., 2024).



Rys. 4.1.4. Uśrednianie maską – wyniki RMSE walidacji uzyskane dla różnych wielkości bloków danych i podzbiorów walidacji krzyżowej. Słupki błędów, wskazujące 95% przedziały ufności, wynikają z różnych enkoderów i architektur testowanych podczas eksperymentów (Szostak i in., 2024).



Rys. 4.1.5. Uśrednianie maską – wyniki RMSE walidacji uzyskane dla różnych architektur i podzbiorów walidacji krzyżowej. Słupki błędów, wskazujące 95% przedziały ufności, wynikają z różnych enkoderów i wielkości bloków danych testowanych podczas eksperymentów (Szostak i in., 2024).

W przypadku metody uśredniania maską użyto jedynie enkoderów typu VGG o różnych głębokościach. Żaden z testowanych enkoderów nie wyróżnia się dokładnością na tle pozostałych (rys. 4.1.3). Rozmiar bloków danych ma wpływ na dokładność modelu, jako że rozmiar bloków danych równy 1 jest zauważalnie gorszy od pozostałych (rys. 4.1.4). W kontekście użytych architektur, PSP-Net dla wszystkich podzbiorów walidacji krzyżowej osiąga wyraźnie lepszą dokładność niż architektury MA-Net i U-Net (rys. 4.1.5).

Jako najlepszą konfigurację wybrano zestaw parametrów (rozmiar bloków danych, enkoder, architektura), dla których RMSE uśredniony dla wszystkich podzbiorów walidacji krzyżowej (wliczając w to zarówno podzbiory z walidacji *stratified*, jak i *all-in-case-out*) był najniższy. Kombinacje parametrów, które osiągnęły najlepszą dokładność, a także ich RMSE uśrednione dla wszystkich podzbiorów walidacji krzyżowej, przedstawiono w tab. 4.1.1. W dalszej części tego rozdziału, omawiane w szczegółach będą tylko te najlepsze konfiguracje metod regresji bezpośredniej oraz uśredniania maską.

Tab. 4.1.1. Konfiguracje hiperparametrów, które uzyskały najlepsze wartości RMSE uśrednione dla wszystkich podzbiorów walidacji krzyżowej (Szostak i in., 2024).

	regresja bezpośrednia	uśrednianie maską
enkoder	VGG16	VGG19
architektura	-	PSP-Net
wielkość bloków danych	1	4
średni RMSE (m)	0.170	0.077

Metryki dokładności

Metryki dokładności zostały obliczone dla wszystkich metod walidacji krzyżowej, studiów przypadków i wariantów metod. Wykorzystano pierwiastek z błędu średniokwadratowego (ang. root-mean-square error, RMSE), średni błąd bezwzględny (ang. mean absolute error, MAE) i średni błąd obciążenia (eng. mean bias error, MBE). W celu porównania zaproponowanego rozwiązania z dokładnością bazową, ten sam zestaw metryk obliczono dla metod wykorzystujących proste próbkowanie NMPT wzdłuż brzegu rzeki i wzdłuż jej środka. Wyniki przedstawiono w tabelach 4.1.2 – 4.1.4.

Tab. 4.1.2. Wartości RMSE (m) uzyskane za pomocą proponowanych metod regresji bezpośredniej i uśredniania maski oraz prostego próbkowania NMPT wzdłuż środka i brzegu rzeki. Dla metod opartych na uczeniu głębokim podano wyniki zarówno technik walidacji krzyżowej typu *stratified*, jak i typu *all-in-case-out*. Podana średnia i odchylenie standardowe próby są obliczane dla wartości ze wszystkich studiów przypadku (Szostak i in., 2024).

studium przypadku	<i>stratified</i>		<i>all-in-case-out</i>		próbkowanie	
	regresja bezpośrednia	uśrednianie maską	regresja bezpośrednia	uśrednianie maską	środek rzeki	przy brzegu
AMO18	0.099	0.035	0.170	0.059	0.219	0.308
GRO20	0.076	0.021	0.124	0.072	0.185	0.228
GRO21	0.107	0.058	0.243	0.117	0.27	0.277
RYB20	0.095	0.048	0.176	0.156	0.449	0.259
RYB21	0.274	0.063	0.337	0.142	0.282	0.404
Średnia	0.130	0.045	0.210	0.109	0.281	0.295
Odch. Stand.	0.081	0.017s	0.083	0.043	0.102	0.067

Tab. 4.1.3. Wartości MAE (m) uzyskane za pomocą proponowanych metod regresji bezpośredniej i uśredniania maski oraz prostego próbkowania NMPT wzdłuż środka i brzegu rzeki. Dla metod opartych na uczeniu głębokim podano wyniki zarówno technik walidacji krzyżowej typu *stratified*, jak i typu *all-in-case-out*. Podana średnia i odchylenie standardowe próby są obliczane dla wartości ze wszystkich studiów przypadku (Szostak i in., 2024).

studium przypadku	<i>stratified</i>		<i>all-in-case-out</i>		próbkowanie	
	regresja bezpośrednia	uśrednianie maską	regresja bezpośrednia	uśrednianie maską	środek rzeki	przy brzegu
AMO18	0.078	0.026	0.121	0.045	0.179	0.176
GRO20	0.059	0.015	0.091	0.06	0.139	0.104
GRO21	0.082	0.028	0.195	0.072	0.117	0.138
RYB20	0.074	0.037	0.127	0.111	0.373	0.157
RYB21	0.169	0.045	0.154	0.096	0.249	0.276
Średnia	0.092	0.030	0.138	0.077	0.211	0.17
Odch. Stand	0.044	0.011	0.039	0.027	0.103	0.065

W tabelach 4.1.2 i 4.1.3 metryki RMSE i MAE jednoznacznie wskazują przewagę rozwiązania opartego na uczeniu maszynowym nad metodą bezpośredniego odczytu poziomu powierzchni wody z NMPT. Nawet przy bardziej rygorystycznej metodzie walidacji krzyżowej typu *all-in-case-out*, metryki dokładności rozwiązania opartego na uczeniu maszynowym są znacznie lepsze od dokładności bazowych uzyskanych bezpośrednim próbkowaniem NMPT. W porównaniu metod walidacji krzyżowej *stratified* i *all-in-case-out* oczywiście ta pierwsza osiąga znacznie lepsze wyniki, jako że jest mniej rygorystyczna. Porównanie metod regresji bezpośredniej oraz uśredniania maską jednoznacznie wskazuje na lepszą dokładność metody uśredniania maską dla wszystkich studiów przypadku.

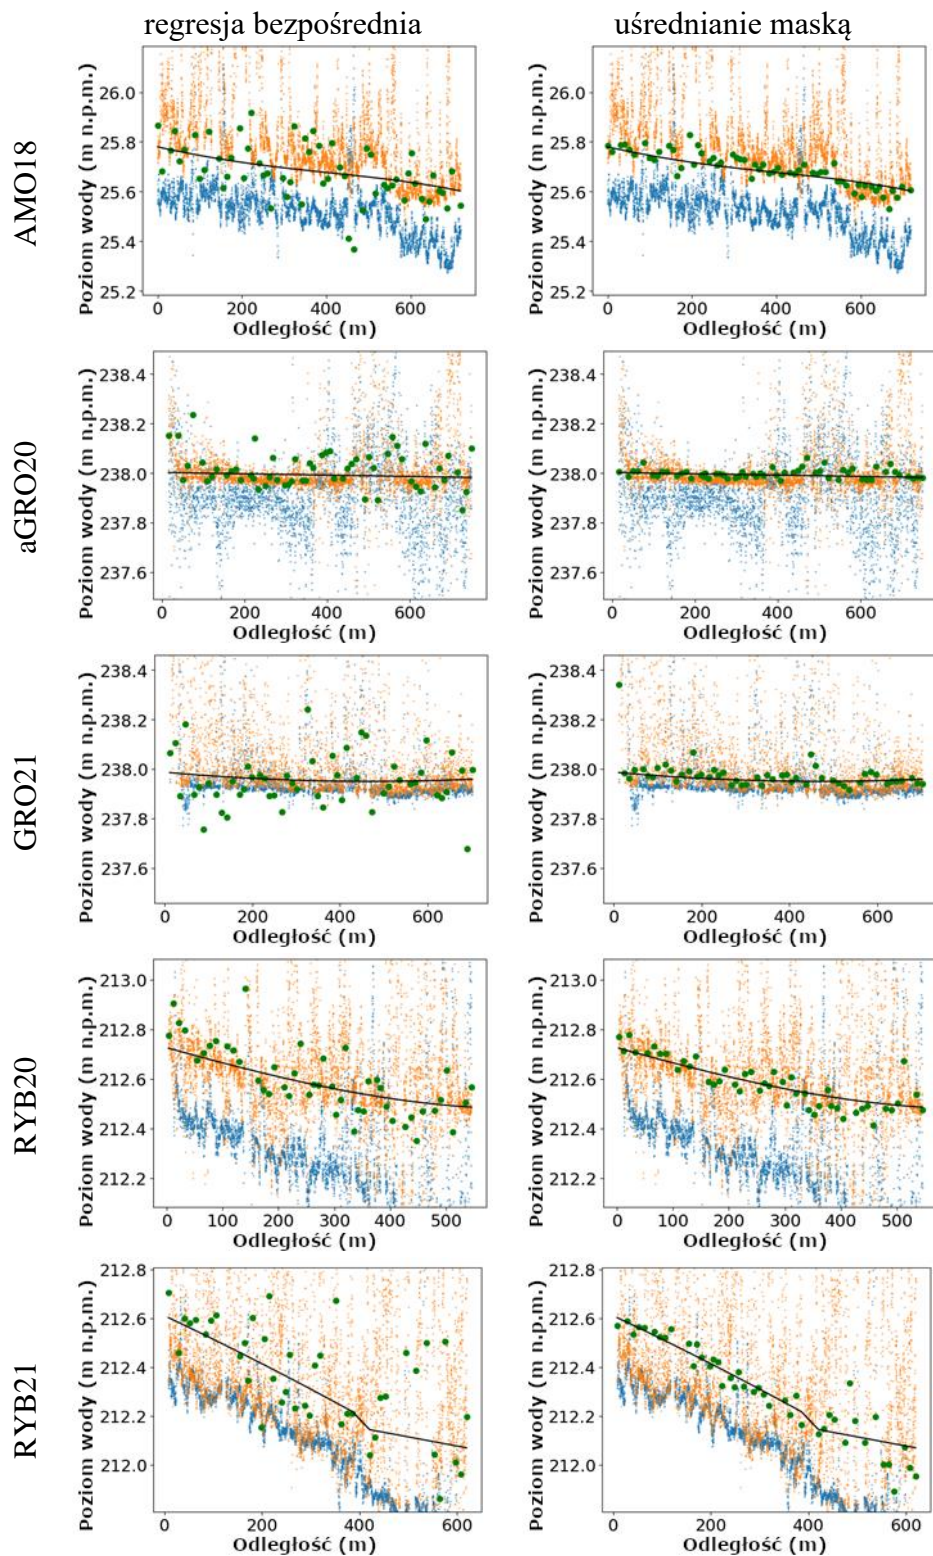
Tab. 4.1.4. Wartości MBE (m) uzyskane za pomocą proponowanych metod regresji bezpośredniej i uśredniania maski oraz prostego próbkowania NMPT wzdłuż środka i brzegu rzeki. Dla metod opartych na uczeniu głębokim podano wyniki zarówno technik walidacji krzyżowej typu *stratified*, jak i typu *all-in-case-out*. Podana średnia i odchylenie standardowe próby są obliczane dla wartości ze wszystkich studiów przypadku (Szostak i in., 2024).

studium przypadku	<i>stratified</i>		<i>all-in-case-out</i>		próbkowanie	
	regresja bezpośrednia	uśrednianie maską	regresja bezpośrednia	uśrednianie maską	środek rzeki	przy brzegu
AMO18	0.008	-0.007	-0.084	-0.015	-0.149	0.161
GRO20	-0.024	-0.007	-0.076	-0.057	-0.071	0.042
GRO21	0.004	-0.018	0.069	-0.064	0.058	0.116
RYB20	-0.013	0.002	0.042	0.059	-0.277	0.036
RYB21	-0.076	0.006	-0.034	-0.004	-0.225	0.102
Średnia	-0.020	-0.005	-0.017	-0.016	-0.133	0.091
Odch. Stand.	0.034	0.009	0.069	0.049	0.132	0.053

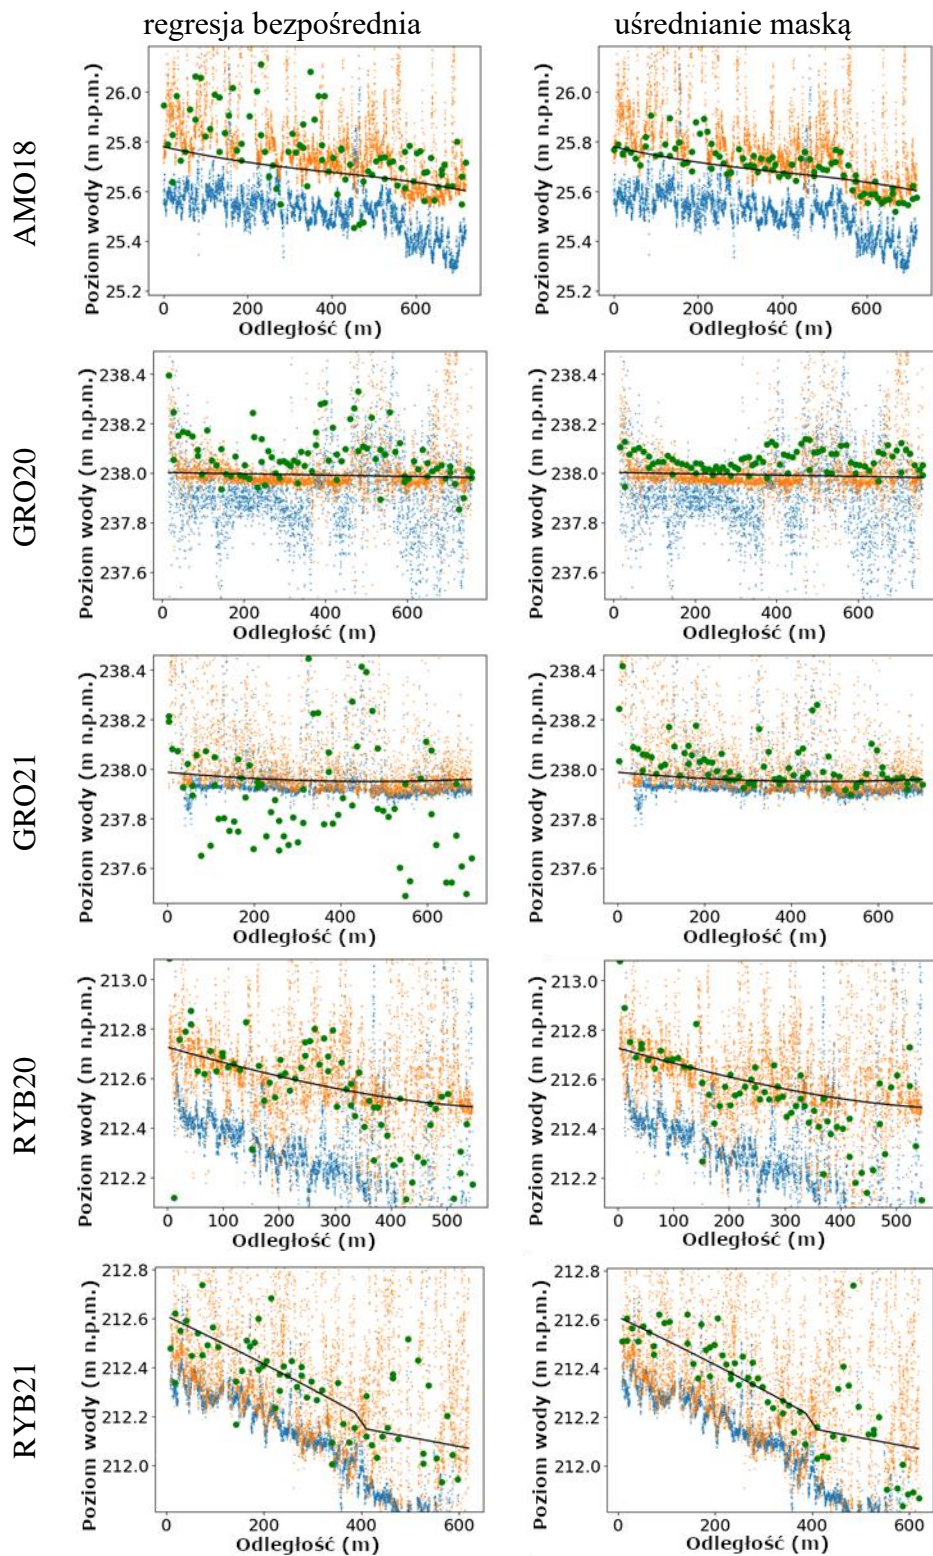
W tabeli 4.1.4 podsumowującej uzyskane metryki MBE, rozwiązanie oparte na uczeniu maszynowym uzyskuje znacząco lepsze wyniki od rozwiązania polegającego na bezpośrednim odczynie poziomu powierzchni wody z NMPT. Dla rozwiązania opartego na uczeniu maszynowym metryki MBE są bliskie zeru. Dla próbkowania wzdłuż środka rzeki osiągnęte są w większości ujemne wartości metryki MBE, wskazując na fakt, że w środku koryta rzeki NMPT odwzorowuje powierzchnię wody poniżej jej rzeczywistego poziomu. Dla próbkowania wzdłuż brzegu rzeki osiągnęte są dodatnie wartości metryki MBE, wskazując na fakt, że NMPT odwzorowuje tam powierzchnię wody powyżej jej rzeczywistego poziomu..

Wizualizacja wyników

Rysunki 4.1.6 i 4.1.7 przedstawiają predykcje poziomu wody w rzece względem odległości od początku odcinka rzeki wykonane na zestawach walidacyjnych zarówno dla walidacji krzyżowej typu *stratified*, jak i typu *all-in-case-out*. Predykcje są porównane z pomiarami rzeczywistego poziomu wody i wartościami uzyskanymi z próbkowania rastra NMPT wzdłuż brzegu rzeki i wzdłuż jej środka.



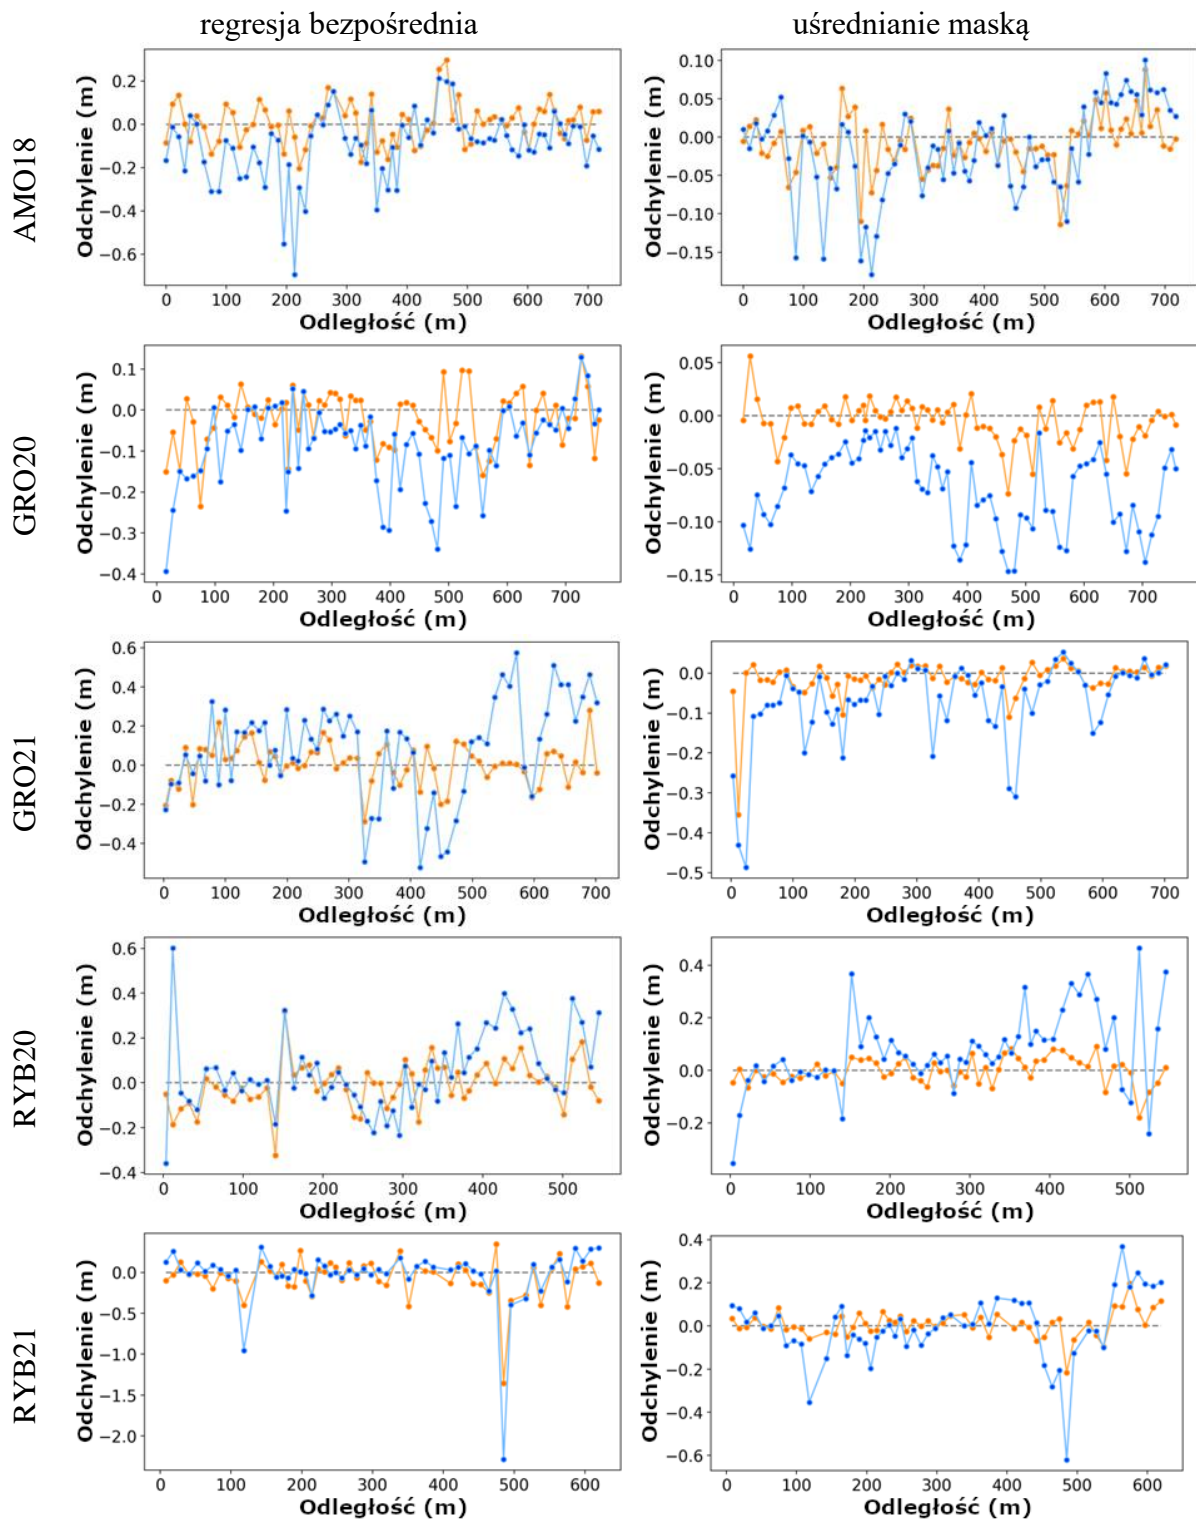
Rys. 4.1.6. Predykcje metodami regresji bezpośredniej i uśredniania maski dla wszystkich studiów przypadków otrzymane metodą walidacji krzyżowej typu *stratified* wykreślone na wykresach względem odległości od początku odcinka rzeki (ciemnozielone punkty). Porównano z wartością rzeczywistą poziomu wody (czarna linia), NMPT próbkowanego wzdłuż brzegu brzegu (pomarańczowe punkty) oraz NMPT próbkowanego wzdłuż środka rzeki (niebieskie punkty). Kolumny oznaczają różne metody, a wiersze odpowiadają poszczególnym studiom przypadku (Szostak i in., 2024).



Rys. 4.1.7. Predykcje metodami regresji bezpośredniej i uśredniania maski dla wszystkich studiów przypadków otrzymane metodą walidacji krzyżowej typu *all-in-case-out* wykreślone na wykresach względem odległości od początku odcinka rzeki (ciemnozielone punkty). Porównano z wartością rzeczywistą poziomu wody (czarna linia), NMPT próbkowanego wzdłuż brzegu brzegu (pomarańczowe punkty) oraz NMPT próbkowanego wzdłuż środka rzeki (niebieskie punkty). Kolumny oznaczają różne metody, a wiersze odpowiadają poszczególnym studiom przypadku (Szostak i in., 2024).

Na rysunkach 4.1.6 oraz 4.1.7 zauważyć można, że predykcje metodą uśredniania maski są bliższe rzeczywistym pomiarom niż predykcje metodą regresji bezpośredniej. Wyraźnie też widać błąd systematyczny dla wartości uzyskanych poprzez próbkowanie NMPT wzdłuż linii środkowej rzeki. Z kolei wartości uzyskane próbkowaniem NMPT wzdłuż brzegu rzeki, często charakteryzują się dużą zmiennością, wykraczając poza skalę wykresów.

Rys. 4.1.8 przedstawia wartości odchylenia predykcji od rzeczywistych poziomów wody (różnicę między wartością rzeczywistą a wartością predykcji) wykreślone na wykresach względem odległości od początku odcinka rzeki. Wykresy narysowano dla każdego studium przypadku i dla każdej metody osobno. Na oddzielnych przebiegach przedstawiono wartości uzyskane zarówno metodą walidacji krzyżowej typu *stratified*, jak i metodą walidacji krzyżowej typu *all-in-case-out*.




Rys. 4.1.8. Wartości odchylenia predykcji od rzeczywistych poziomów wody (różnicę między wartością rzeczywistą a wartością predykcji) wykresłone na wykresach względem odległości od początku odcinka rzeki. Wykresy narysowano dla każdego studium przypadku (wiersze) i dla każdej metody osobno (kolumny). Na oddzielnych przebiegach przedstawiono wartości uzyskane zarówno metodą walidacji krzyżowej typu *stratified* (kolor pomarańczowy), jak i metodą walidacji krzyżowej typu *all-in-case-out* (kolor niebieski) (Szostak i in., 2024).

Rys. 4.1.8. potwierdza gorszą dokładność osiągniętą w czasie walidacji typu *all-in-case-out* w porównaniu z walidacją typu *stratified*. Dla niektórych studiów przypadku widoczny jest również niewielki błąd systematyczny dla walidacji *all-in-case-out*.

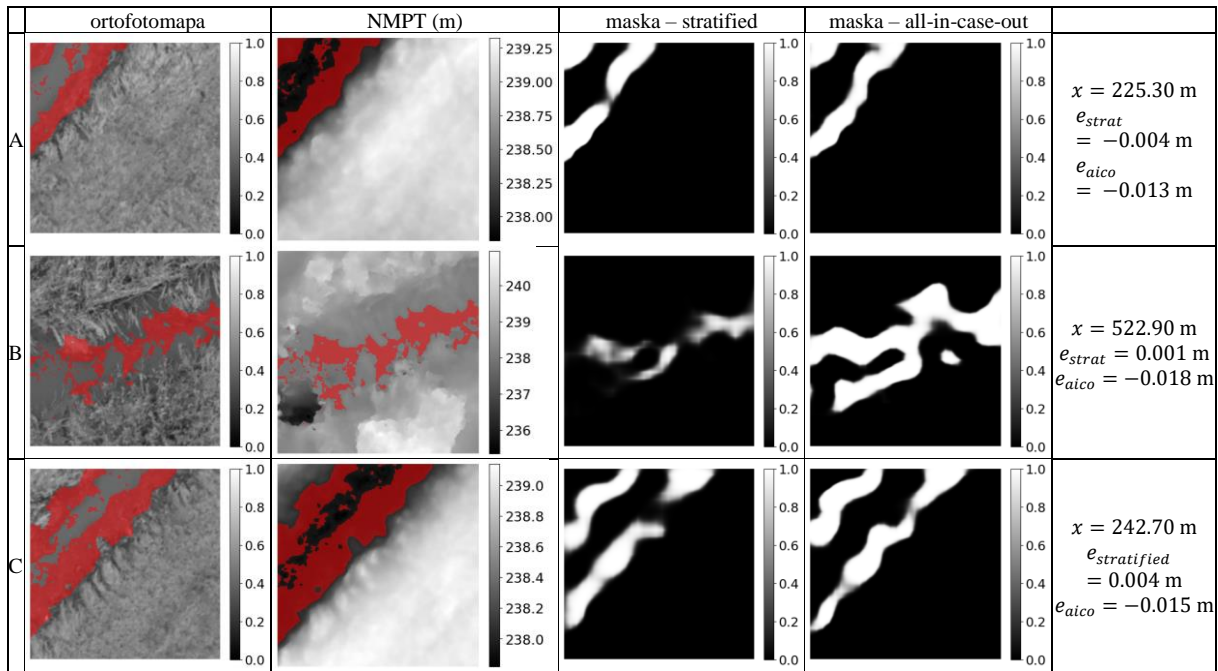
Wizualizacje predykcji masek wag

W rozwiązaniu uśredniania maską maska wagi jest używana do próbkowania wartości poziomu powierzchni wody z NMPT. W tym podejściu podczas treningu nie używano wzorcowych masek i sieć neuronowa samodzielnie uczyła się generować optymalną maskę wag poprzez optymalizację funkcji straty MSE. Możliwe jest wizualizowanie maski używanej do obliczania poziomu wody, co zwiększa wartość rozwiązania w kontekście objaśnialności sieci neuronowej (ang. explainability), czyli możliwości sieci do nie tylko dostarczania celnych predykcji ale również do wyjaśniania sposobu, w jaki doszła do danego rozwiązania.

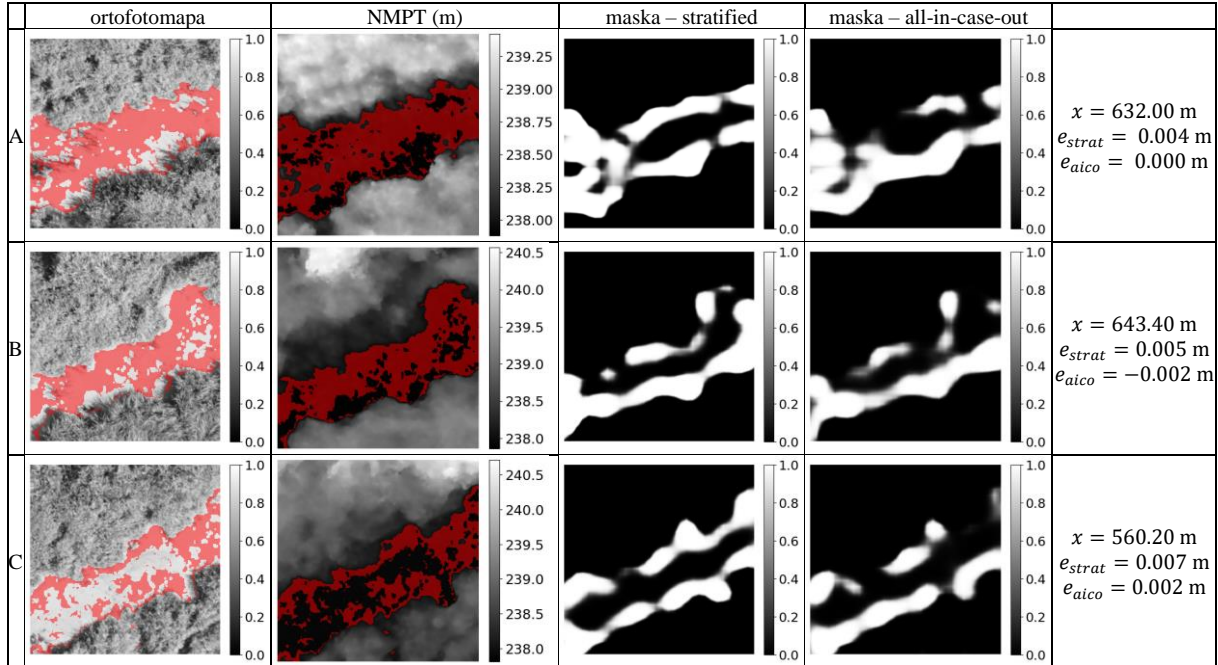
Aby zobrazować charakter próbek, które zostały pomyślnie uwzględnione w rozwiązaniu uśredniania maską, dla każdego studium przypadku przedstawiono trzy próbki charakteryzujące się najmniejszymi wartościami rezydualnymi. Wyniki przedstawiono na rysunkach 4.1.9 – 4.1.13.




Rys. 4.1.9. Próbkki ortofotomapy, NMPT i maski wag uzyskane podczas walidacji krzyżowej typu *stratified* i *all-in-case-out* dla trzech próbek ze studium przypadku AMO18, dla których uzyskano najdokładniejsze predykcje. Podana wartość x to odległość od początku odcinka rzeki, w której znajduje się próbka. Wartości e_{strat} i e_{aico} odpowiadają odchyleniom predykcji względem rzeczywistych wartości uzyskanych odpowiednio przy użyciu walidacji krzyżowych typu *stratified* i *all-in-case-out*. Obszary, w których NMPT jest równy rzeczywistemu poziomowi wody z marginesem błędów $\pm 5 \text{ cm}$, oznaczono czerwonym kolorem na ortofotomapie i NMPT (Szostak i in., 2024).




Rys. 4.1.10. Próbkę ortofotomapy, NMPT i maski wag uzyskane podczas walidacji krzyżowej typu *stratified* i *all-in-case-out* dla trzech próbek ze studium przypadku GRO20, dla których uzyskano najdokładniejsze predykcje. Podana wartość x to odległość od początku odcinka rzeki, w której znajduje się próbka. Wartości e_{strat} i e_{aico} odpowiadają odchyleniom predykcji względem rzeczywistych wartości uzyskanych odpowiednio przy użyciu walidacji krzyżowych typu *stratified* i *all-in-case-out*. Obszary, w których NMPT jest równy rzeczywistemu poziomowi wody z marginesem błędów $\pm 5 \text{ cm}$, oznaczono czerwonym kolorem na ortofotomapie i NMPT (Szostak i in., 2024).



Rys. 4.1.11. Próbkę ortofotomapy, NMPT i maski wag uzyskane podczas walidacji krzyżowej typu *stratified* i *all-in-case-out* dla trzech próbek ze studium przypadku GRO21, dla których uzyskano najdokładniejsze predykcje. Podana wartość x to odległość od początku odcinka rzeki, w której znajduje się próbka. Wartości e_{strat} i e_{aico} odpowiadają odchyleniom predykcji względem rzeczywistych wartości uzyskanych odpowiednio przy użyciu walidacji krzyżowych typu *stratified* i *all-in-case-out*. Obszary, w których NMPT jest równy rzeczywistemu poziomowi wody z marginesem błędów $\pm 5 \text{ cm}$, oznaczono czerwonym kolorem na ortofotomapie i NMPT (Szostak i in., 2024).




Rys. 4.1.12. Próbkę ortofotomapy, NMPT i maski wag uzyskane podczas walidacji krzyżowej typu *stratified* i *all-in-case-out* dla trzech próbek ze studium przypadku RYB20, dla których uzyskano najdokładniejsze predykcje. Podana wartość x to odległość od początku odcinka rzeki, w której znajduje się próbka. Wartości e_{strat} i e_{aico} odpowiadają odchyleniom predykcji względem rzeczywistych wartości uzyskanych odpowiednio przy użyciu walidacji krzyżowych typu *stratified* i *all-in-case-out*. Obszary, w których NMPT jest równy rzeczywistemu poziomowi wody z marginesem błędów $\pm 5 \text{ cm}$, oznaczono czerwonym kolorem na ortofotomapie i NMPT (Szostak i in., 2024).




Rys. 4.1.13. Próbkę ortofotomapy, NMPT i maski wag uzyskane podczas walidacji krzyżowej typu *stratified* i *all-in-case-out* dla trzech próbek ze studium przypadku RYB21, dla których uzyskano najdokładniejsze predykcje. Podana wartość x to odległość od początku odcinka rzeki, w której znajduje się próbka. Wartości e_{strat} i e_{aico} odpowiadają odchyleniom predykcji względem rzeczywistych wartości uzyskanych odpowiednio przy użyciu walidacji krzyżowych typu *stratified* i *all-in-case-out*. Obszary, w których NMPT jest równy rzeczywistemu poziomowi wody z marginesem błędów $\pm 5 \text{ cm}$, oznaczono czerwonym kolorem na ortofotomapie i NMPT (Szostak i in., 2024).

Na rysunkach 4.1.9 – 4.1.13 widzimy, że próbki dla których osiągnięto najdokładniejsze predykcje w większości nie zawierają żadnych wyróżniających elementów takich jak np. drzewa.


Aby określić czynniki przyczyniające się do zmniejszenia dokładności proponowanego rozwiązania, przeprowadzono dalsze analizy. Dla każdego studium przypadku wygenerowano reprezentacje graficzne podobne do rysunków 4.1.9 – 4.1.13, zawierające próbki ortofotomapy i NMPT wraz z maskami wag uzyskanymi w rozwiązaniu uśredniania maską. Tym razem wizualizacje koncentrują się na trzech próbkach wykazujących największe odchylenia predykcji względem rzeczywistego poziomu wody. Wyniki tych analiz przedstawiono na rysunkach 4.1.14 – 4.1.18.



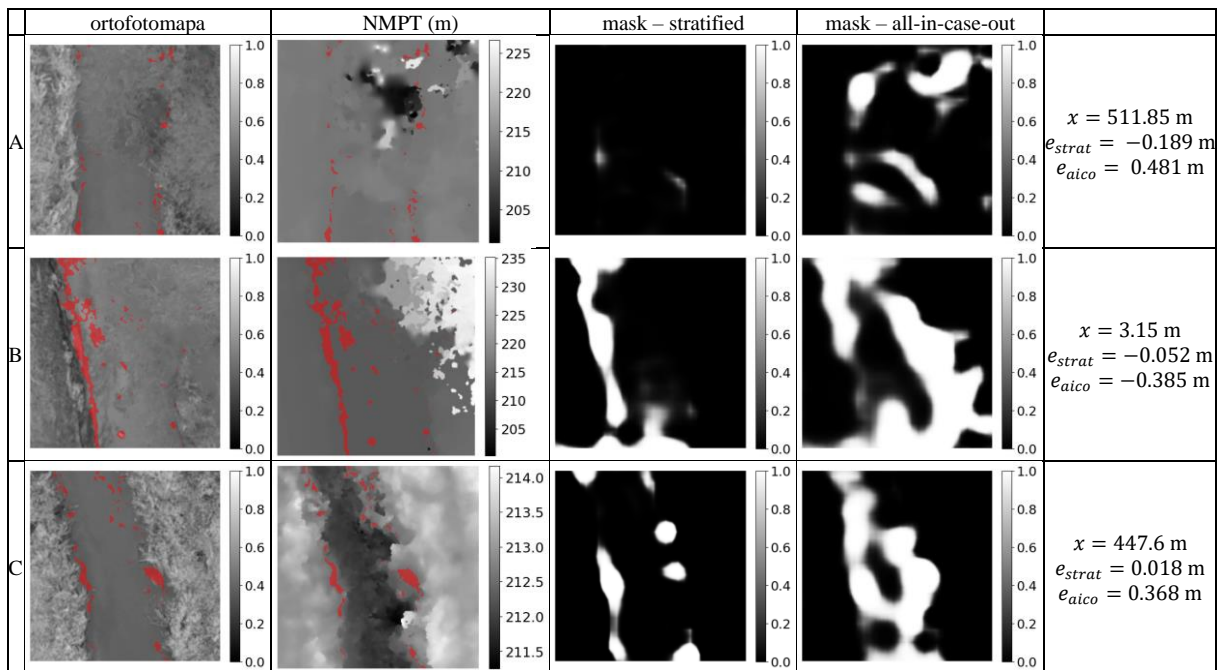
Rys. 4.1.14. Próbkę ortofotomapy, NMPT i maski wag uzyskane podczas walidacji krzyżowej typu *stratified* i *all-in-case-out* dla trzech próbek ze studium przypadku AMO18, dla których uzyskano najmniej dokładne predykcje. Podana wartość x to odległość od początku odcinka rzeki, w której znajduje się próbka. Wartości e_{strat} i e_{aico} odpowiadają odchyleniom predykcji względem rzeczywistych wartości uzyskanych odpowiednio przy użyciu walidacji krzyżowych typu *stratified* i *all-in-case-out*. Obszary, w których NMPT jest równy rzeczywistemu poziomowi wody z marginesem błędów $\pm 5 \text{ cm}$, oznaczono czerwonym kolorem na ortofotomapie i NMPT (Szostak i in., 2024).



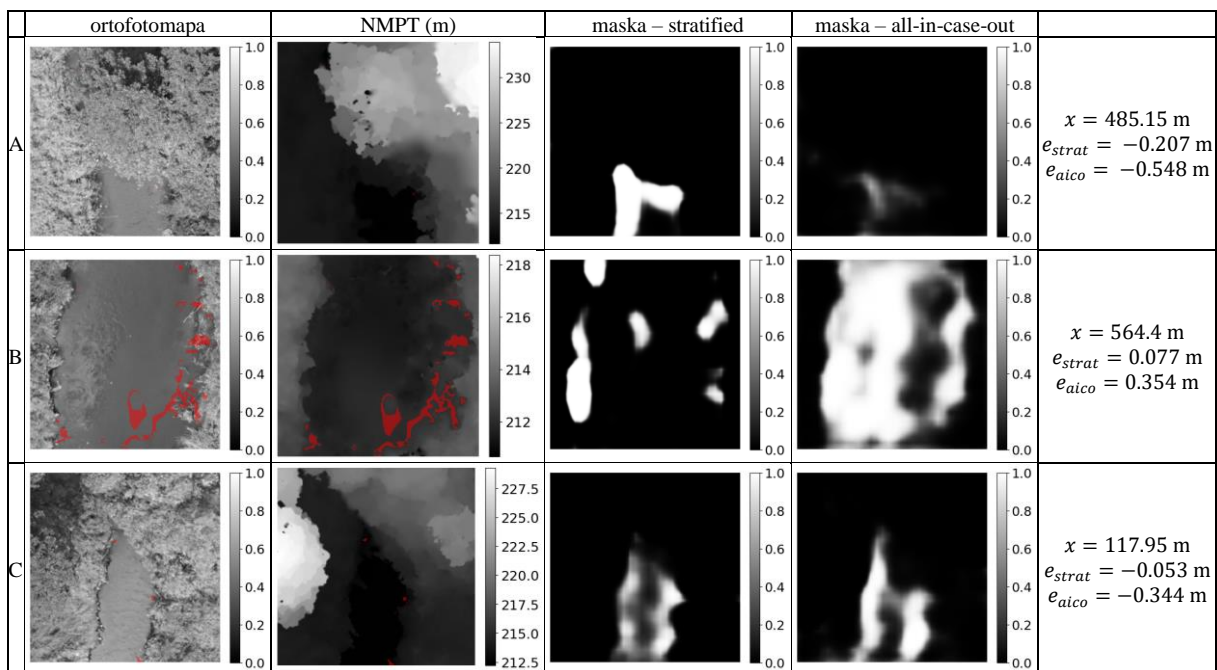
Rys. 4.1.15. Próbkę ortofotomapy, NMPT i maski wag uzyskane podczas walidacji krzyżowej typu *stratified* i *all-in-case-out* dla trzech próbek ze studium przypadku GRO20, dla których uzyskano najmniej dokładne predykcje. Podana wartość x to odległość od początku odcinka rzeki, w której znajduje się próbka. Wartości e_{strat} i e_{aico} odpowiadają odchyleniom predykcji względem rzeczywistych wartości uzyskanych odpowiednio przy użyciu walidacji krzyżowych typu *stratified* i *all-in-case-out*. Obszary, w których NMPT jest równy rzeczywistemu poziomowi wody z marginesem błędów ± 5 cm, są oznaczone czerwonym kolorem na ortofotomapie i NMPT (Szostak i in., 2024).



Rys. 4.1.16. Próbkę ortofotomapy, NMPT i maski wag uzyskane podczas walidacji krzyżowej typu *stratified* i *all-in-case-out* dla trzech próbek ze studium przypadku GRO21, dla których uzyskano najmniej dokładne predykcje. Podana wartość x to odległość od początku odcinka rzeki, w której znajduje się próbka. Wartości e_{strat} i e_{aico} odpowiadają odchyleniom predykcji względem rzeczywistych wartości uzyskanych odpowiednio przy użyciu walidacji krzyżowych typu *stratified* i *all-in-case-out*. Obszary, w których NMPT jest równy rzeczywistemu poziomowi wody z marginesem błędów ± 5 cm, są oznaczone czerwonym kolorem na ortofotomapie i NMPT (Szostak i in., 2024).



Rys. 4.1.17. Próbkę ortofotomapy, NMPT i maski wag uzyskane podczas walidacji krzyżowej typu *stratified* i *all-in-case-out* dla trzech próbek ze studium przypadku RYB20, dla których uzyskano najmniej dokładne predykcje. Podana wartość x to odległość od początku odcinka rzeki, w której znajduje się próbka. Wartości e_{strat} i e_{aico} odpowiadają odchyleniom predykcji względem rzeczywistych wartości uzyskanych odpowiednio przy użyciu walidacji krzyżowych typu *stratified* i *all-in-case-out*. Obszary, w których NMPT jest równy rzeczywistemu poziomowi wody z marginesem błędów $\pm 5 \text{ cm}$, są oznaczone czerwonym kolorem na ortofotomapie i NMPT (Szostak i in., 2024).



Rys. 4.1.18. Próbkę ortofotomapy, NMPT i maski wag uzyskane podczas walidacji krzyżowej typu *stratified* i *all-in-case-out* dla trzech próbek ze studium przypadku RYB21, dla których uzyskano najmniej dokładne predykcje. Podana wartość x to odległość od początku odcinka rzeki, w której znajduje się próbka. Wartości e_{strat} i e_{aico} odpowiadają odchyleniom predykcji względem rzeczywistych wartości uzyskanych odpowiednio przy użyciu walidacji krzyżowych typu *stratified* i *all-in-case-out*. Obszary, w których NMPT jest równy rzeczywistemu poziomowi wody z marginesem błędów $\pm 5 \text{ cm}$, są oznaczone czerwonym kolorem na ortofotomapie i NMPT (Szostak i in., 2024).

Na rysunkach 4.1.14 – 4.1.18 widzimy, że próbki dla których osiągnięto najmniej dokładne predykcje w większości zawierają wyróżniające elementy takie jak drzewa, porastające powierzchnię wody trawy, czy duże zaburzenia odwzorowania fotogrametrycznego powierzchni wody.

Na podstawie wszystkich zaprezentowanych wizualizacji uzyskanych masek wag można określić sposób w jaki algorytm uczenia maszynowego nauczył się próbkować NMPT. Przede wszystkim próbkowane są obszary wody znajdujące się przy brzegach rzeki. Mimo tego podobieństwa do manualnego próbkowania NMPT wzdłuż linii biegnącej przy brzegu rzeki, rozwiązanie oparte na uczeniu maszynowym osiąga znacznie lepsze rezultaty. Prawdopodobnie jest to związane z faktem, że algorytm jest w stanie stopniować wagi pikseli oraz cechuje się elastycznością rezygnując z niektórych obszarów, które pomimo, że znajdują się przy brzegu rzeki, zawierają niedopuszczalne zaburzenie mogące negatywnie wpłynąć na uśredniony wynik.

Dane

Pliki rastrowe i wektorowe użyte w badaniu są dostępne online w repozytorium Zenodo pod adresem <https://doi.org/10.5281/zenodo.7185594> (dostęp 27 stycznia 2024). Kody źródłowe oraz wstępnie przetworzony zestaw danych do uczenia maszynowego są dostępne online w repozytorium GitHub pod adresem <https://github.com/radekszostak/stream-wse-uav-ml> (dostęp 27 stycznia 2024).

Wnioski

W opisanym badaniu przetestowano możliwość zastosowania uczenia głębokiego do oszacowania poziomu powierzchni wody małego strumienia z zaburzonego fotogrametrycznego NMPT i ortofotomapy. Zadanie okazało się nietrywialne, gdyż najbardziej oczywiste rozwiązanie w postaci bezpośredniej regresji z wykorzystaniem autoenkodera okazało się nieskuteczne. Dopiero odpowiednio dostosowana architektura, która obejmowała przewidywanie maski wag, a następnie wykorzystanie jej do próbkowania NMPT, dała zadowalający wynik.

Główne kroki zaproponowanego rozwiązania obejmują: (i) wykonanie pomiaru fotogrametrycznego nad obszarem rzeki i osadzenie uzyskanych map w geograficznym układzie odniesienia, na przykład poprzez wykorzystanie naziemnych punktów kontrolnych. (ii) wyodrębnienie próbek z rastrów NMPT i ortofotomapy, które obejmują obszar strumienia i brzeg. (iii) wykorzystanie wytrenowanego modelu do oszacowania poziomu wody. Poprawę

dokładności można osiągnąć poprzez dostrojenie modelu przy pomocy danych z konkretnego studium przypadku.

Rozwiązanie zostało zweryfikowane przy użyciu dwóch metod walidacji krzyżowej: *stratified* i *all-in-case-out*. Metody te różnią się sposobami wykorzystania do walidacji próbek ze studiów przypadków niedostępnych dla modelu podczas szkolenia. W zależności od studium przypadku i poziomu rygorystyczności walidacji krzyżowej, zaproponowane rozwiązanie osiąga RMSE w zakresie od 2 cm do 16 cm. W porównaniu z prostą metodą bezpośredniego próbkowania fotogrametrycznego NMPT, zaproponowane rozwiązanie osiąga średnio o 84% niższy RMSE podczas walidacji krzyżowej typu *stratified* i o 62% niższy RMSE podczas walidacji krzyżowej typu *all-in-case-out*. Przewyższając dotychczasowe metody oparte na fotogrametrii BSP, zaproponowane rozwiązanie znacznie zwiększa potencjał wykorzystania fotogrametrii BSP do szacowania poziomu wody w małych strumieniach.

Wykorzystując dane z innego badania, zaproponowane rozwiązanie zostało porównane w tym samym studium przypadku z innymi metodami opartymi na BSP. Dla tego przypadku, zaproponowane rozwiązanie osiągnęło wynik RMSE wynoszący 5,9 cm dla walidacji krzyżowej typu *all-in-case-out* i 3,5 cm dla walidacji krzyżowej typu *stratified*. Są to rezultaty zbliżone do wyniku osiągniętego przez metodę wykorzystującą radar (RMSE 3 cm), która jest uważana aktualnie za najdokładniejszą dostępną metodę.

Zaproponowane rozwiązanie charakteryzuje się wysokim poziomem uogólniania, zapewniając zadowalające prognozy dla danych ze studiów przypadków niedostępnych podczas szkolenia. Kolejną cechą rozwiązania jest jego wytłumaczalność, jako że maski pełniące funkcję pośrednią w procesie predykcji dostarczają interesujących informacji na temat obszarów NMPT, które prawidłowo reprezentują poziom wody.


Pomimo zalet wykorzystania BSP do pomiaru poziomu wody w rzece, takich jak możliwość działania w niedostępnym terenie i uzyskiwania rozłożonych przestrzennie pomiarów, należy zdawać sobie sprawę z pewnych ograniczeń utrudniających korzystanie z bezzałogowych statków powietrznych związanych z niekorzystnymi warunkami pogodowymi (silny wiatr, opady lub mgła), ograniczeniami lotów nad niektórymi strefami wynikającymi z przepisów lotniczych lub większą złożonością przetwarzania danych.

4.2. Wyniki automatycznej kalibracji lotniczych obrazów termowizyjnych przy użyciu optymalizacji metodą gradientów

Eksperymenty ewaluujące dokładność pomiaru przy pomocy kamer termowizyjnych

W celu przyjrzenia się problemom pomiaru temperatury przy pomocy mikrobolometrycznej kamery termowizyjnej, przeprowadzono w kontrolowanych warunkach 2 eksperymenty.

W pierwszym z eksperymentów kamerę termowizyjną umieszczono w odległości 20 cm ponad lustrem wody znajdującej się w waniencie i rejestrowano zdjęcia zmieniającej się temperatury wody z jednoczesnym pomiarem referencyjnym przy użyciu termopary. Wymiary wanienki wynosiły 40×70 cm i wypełniona była wodą do głębokości ok. 25 cm. Przed rozpoczęciem właściwego eksperymentu kamera była włączona i rejestrowała obrazy przez godzinę, aby się rozgrzać i uzyskać równowagę temperaturową. Niskie temperatury wody zostały osiągnięte poprzez wsypanie lodu. Następnie podczas zbierania danych woda była stopniowo podgrzewana przy pomocy elektrycznej grzałki połączonej z turbiną zapewniającą mieszanie się wody.




Rys. 4.2.1. Wyniki pierwszego eksperymentu. Surowe dane z kamery względem temperatury zmierzonej termoparą (a), temperatura zmierzona kamerą termowizyjną względem temperatury zmierzonej termoparą (b), błąd pomiaru kamery termowizyjnej (różnica temperatury zmierzonej termoparą i kamerą). Przerwane linie wyznaczają bezbłędny pomiar.

Na wykresie surowych danych termowizyjnych (rys. 4.2.1.a) widzimy, że ich zmienność względem zmierzonej termoparą temperatury nie jest monotoniczna. Oznacza to, że oprogramowanie kamery skaluje sygnał z bolometrów w zmienny sposób. Informacje o parametrach skalujących prawdopodobnie są zakodowane w metadanych zdjęcia i nie są dostępne dla użytkownika. Surowe dane mogą zostać przeliczone na temperatury przy pomocy zamkniętego oprogramowania producenta. Uniemożliwia to kalibrację operującą na surowych danych (digital numbers) stosowaną w wielu publikacjach. Rysunki 4.2.1.b oraz 4.2.1.c wykorzystują temperatury odczytane ze zdjęć przy pomocy oprogramowania producenta

kamery. Widzimy na nich, że pomiar przy użyciu kamery różni się od temperatury wzorcowej nawet o 7.5 °C.

Drugi eksperyment miał na celu zbadanie wpływu zmian stanu kamery zachodzących po jej uruchomieniu na odczyty temperatury dostarczane przez oprogramowanie kamery. W tym przypadku wykonywano zdjęcia termiczne jednorodnego obiektu o stałej temperaturze i pomiary rozpoczęto od razu po włączeniu kamery. Rezultaty eksperymentu przedstawiono na rys. 4.2.2.



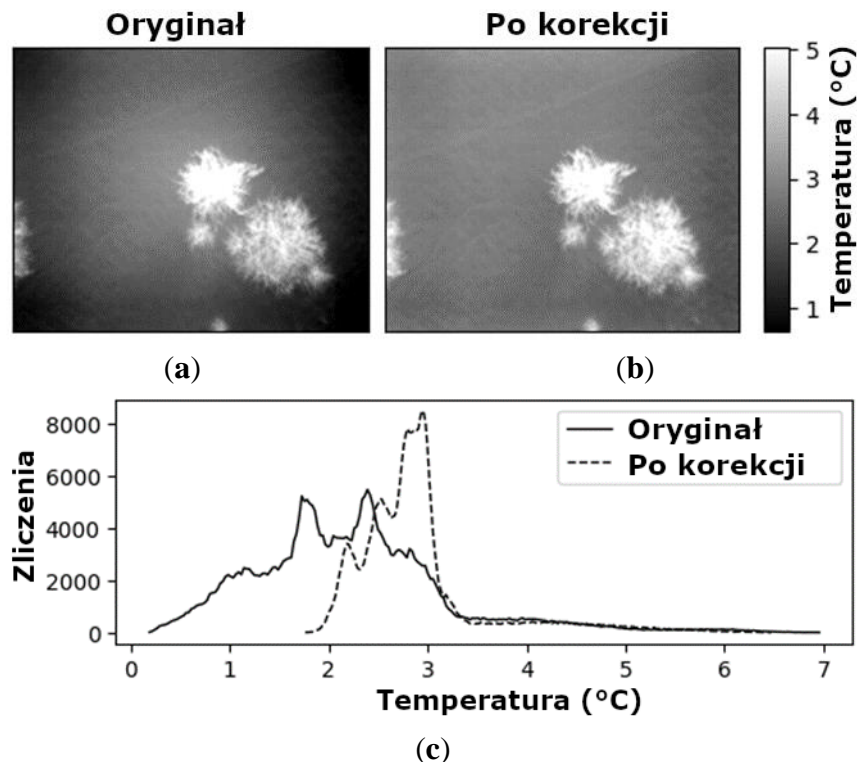
Rys. 4.2.2. Wyniki drugiego eksperymentu. Przebieg czasowy zmierzonej przy pomocy oprogramowania kamery termowizyjnej temperatury i surowych danych z kamery termowizyjnej.

W drugim eksperymencie kolejny raz potwierdzone zostaje, że surowe dane zawarte w metadanych pliku zdjęcia termicznego wymagają przeskalowania, aby były użyteczne do ewentualnej obróbki. Nieciągłość surowych danych wskazuje, że czynnik skalujący zmieniał się podczas trwania eksperymentu. Pomimo prób zastosowania inżynierii wstecznej, nie udało się odkodować czynników skalujących z metadanych zdjęcia. W takiej sytuacji pozostaje poleganie na oprogramowaniu dostarczonej przez producenta. Przy jego pomocy uzyskano wartości temperatur. Widzimy, że z czasem pomiar się stabilizuje. Potwierdza to zalecenia, że przed rozpoczęciem pomiaru należy rozgrzać kamerę. W tym przypadku stan równowagi osiągnięto po około 30 minutach. Temperatura ustaliła się w okolicy 27.5 °C, podczas gdy rzeczywista temperatura obiektu wynosiła 25 °C.


Korekcja efektu winiety

Do korekcji efektu winiety zastosowano algorytm typu *single image*. Z tego powodu korygowane obrazy podatne są na błędne interpretacje, a w konsekwencji na błędną korektę

efektu winiety. Rys. 4.2.3 przedstawia przykład udanej korekcji efektu winiety. W tym przypadku odchylenie standardowe temperatury na obrazie zmniejszyło się w wyniku korekcji, co objawia się zwężeniem histogramu wartości temperatury pikseli. Rys. 4.2.4 przedstawia błędną korekcję efektu winiety, gdzie prawdopodobnie rzeka widoczna przy lewej krawędzi obrazu spowodowała błędną interpretację. W tym przypadku korekta spowodowała wzrost odchylenia standardowego temperatury obrazu, co objawia się poszerzeniem histogramu wartości pikseli.




Rys. 4.2.3. Przykład udanej korekcji efektu winiety. Oryginalny obraz (a), obraz po korekcji (b), histogramy obrazów z przed i po korekcji (c) (Szostak i in., 2023).



Rys. 4.2.4. Przykład nieudanej korekcji efektu winiety. Oryginalny obraz (a), obraz po korekcji (b), histogramy obrazów z przed i po korekcji (c) (Szostak i in., 2023).


W celu ilościowej oceny skuteczności algorytmu przetestowano go na zestawie 3037 obrazów. Miarą skuteczności algorytmu była zmiana odchylenia standardowego temperatury obrazu przed i po korekcie. Dla 74,4% (2261) obrazów uzyskano zmniejszenie odchylenia standardowego średnio o $-0,07$ °C, a dla 25,6% (776) obrazów uzyskano wzrost odchylenia standardowego średnio o $0,01$ °C. Szczegółowy rozkład zmian odchylenia standardowego temperatury w wyniku korekcji efektu winiety przedstawiono na rys. 4.2.5.




Rys. 4.2.5. Zmiana odchylenia standardowego temperatury obrazu w wyniku zastosowania algorytmu redukcji efektu winiety. Wartości ujemne oznaczają poprawę (obniżenie odchylenia standardowego w skorygowanym obrazie). Linia przerywana umieszczona w wartości 0 °C (brak zmiany odchylenia standardowego) (Szostak i in., 2023).

Ocena wizualna


Rysunki 4.2.6 – 4.2.10 przedstawiają fragmenty mozaik obrazów termowizyjnych przed i po kalibracji dla każdego podzbioru zdjęć (tab. 3.2.1). Należy zauważyć, że obrazy nie są fotogrametrycznymi ortomozaikami, ale mozaikami obrazów utworzonych z bezpośredniego ułożenia zdjęć.




Rys. 4.2.6. Podzbiór A – fragment mozaiki obrazów przed i po kalibracji (Szostak i in., 2023).




Rys. 4.2.7. Podzbiór B – fragment mozaiki obrazów przed i po kalibracji (Szostak i in., 2023).



Rys. 4.2.8. Podzbiór C – fragment mozaiki obrazów przed i po kalibracji (Szostak i in., 2023).



Rys. 4.2.9. Podzbiór D – fragment mozaiki obrazów przed i po kalibracji (Szostak i in., 2023).



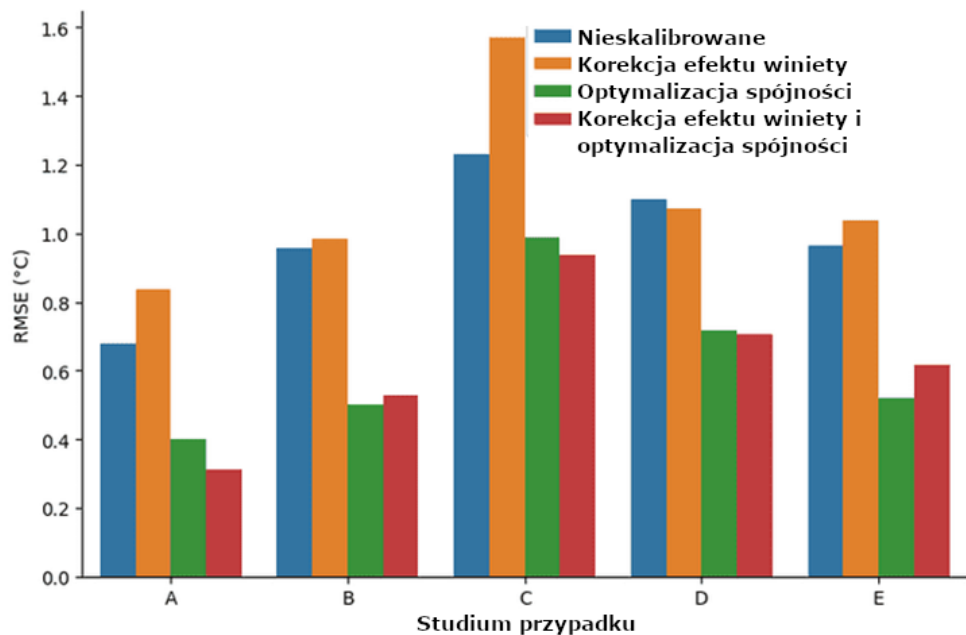
Rys. 4.2.10. Podzbiór E – fragment mozaiki obrazów przed i po kalibracji (Szostak i in., 2023).

Wizualne porównanie mozaik obrazów termowizyjnych przed i po kalibracji pokazuje poprawę w zakresie wahań temperatury, szczególnie między kolejnymi przelotami, które są zauważalne jako równoległe pasy o wyróżniającej się temperaturze we wszystkich nieskalibrowanych mozaikach. Algorytm radzi sobie również z korektą wyróżniających się temperatur zmierzonych na początku lotu, gdy kamera się nagrzewa, co widać po lewej stronie mozaiki przypadku D (rys. 4.2.9). Ponadto korekcja obrazów z przypadków A (rys. 4.2.6) i B (rys. 4.2.7) pozwoliła wykryć cieplejszy dopływ strumienia, który jest zasilany przez cieplejsze wody gruntowe.

Temperatura wody

Rys. 4.2.11 podsumowuje błędy średniokwadratowe pomiarów temperatury rzeki uzyskanych z obrazów termowizyjnych w różnych konfiguracjach procedury kalibracji: nieskalibrowane, tylko z redukcją efektu winiety, tylko z minimalizacją różnic temperatury pomiędzy przekrywającymi się częściami zdjęć oraz po zastosowaniu algorytmów redukcji efektu winiety i minimalizacji różnic pomiędzy przekrywającymi się częściami zdjęć. Aby

skupić się wyłącznie na precyzji pomiaru, wszystkie metryki (w tym dla nieskalibrowanych zdjęć) zostały obliczone przy użyciu obrazów poddanych wyrównaniu względem punktów referencyjnych.

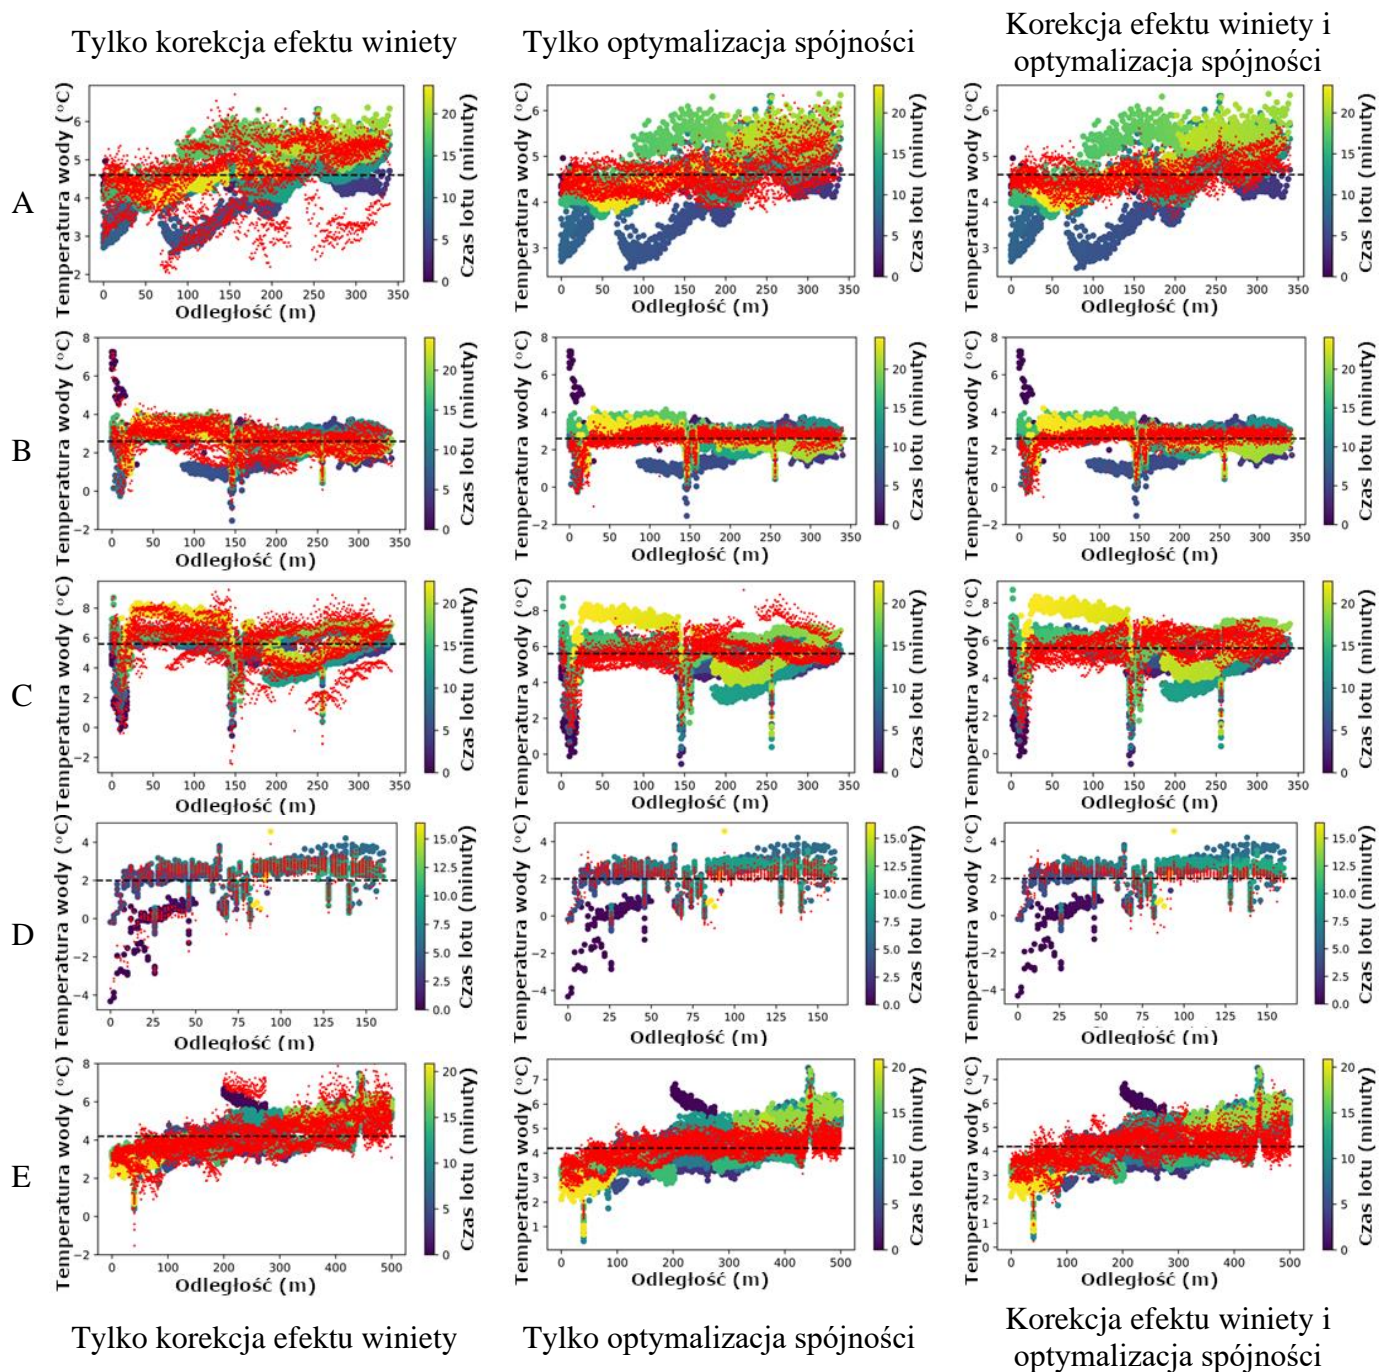


Rys. 4.2.11. Błędy średniokwadratowe temperatury wody przed kalibracją, tylko po korekcji efektu winiety, tylko po minimalizacji różnic temperatury między się zdjęciami oraz po korekcji efektu winiety i minimalizacji różnic temperatury między się zdjęciami (Szostak i in., 2023).

Zastosowanie samego algorytmu korekcji efektu winiety spowodowało wzrost RMSE w większości przypadków, co oznacza, że precyzja odczytu temperatury obrazu została zmniejszona. Niewielką poprawę uzyskano w przypadku D ze zmianą RMSE o $-0,03$ °C. Zastosowanie algorytmu minimalizacji różnic temperatury między przekrywającymi się obrazami znacznie zmniejszyło RMSE we wszystkich przypadkach. Największą poprawę metryki zanotowano dla przypadku B, gdzie osiągnięto prawie 50% zmniejszenie błędu średniokwadratowego (z RMSE $0,95$ °C przed zastosowaniem algorytmu do $0,50$ °C po nim). Zastosowanie obu algorytmów spowodowało dalszą poprawę precyzji w trzech przypadkach, a w pozostałych dwóch wyniki RMSE wzrósł w porównaniu z samą optymalizacją, ale nadal był znacznie niższy niż w przypadku nieprzetworzonego obrazu.

Rys. 4.2.12 przedstawia temperatury odczytane wzdłuż linii biegnącej przez środek strumienia z obrazów przetworzonych przy użyciu różnych konfiguracji korekcji efektu winiety i minimalizacji różnicy temperatur między przekrywającymi się obrazami. Ponieważ każdy punkt rzeki może być obecny na wielu nakładających się zdjęciach, uzyskiwano kilka odczytów temperatury dla tej samej lokalizacji. Procedura minimalizacji różnicy temperatury między przekrywającymi się obrazami zastosowana do obrazów z początkowej fazy lotu, gdy kamera

się nagrzewa (ciemnoniebieskie znaczniki na rys. 4.2.12), w większości przypadków dała prawidłowe odczyty temperatury. Pozostałe wartości odstające w odczytach temperatury rzeki, które nie zostały skompensowane przez algorytm, na przykład trzy silnie ujemne piki w przypadku C na rys. 4.2.12, okazały się być próbkowane na roślinności wystającej ponad powierzchnię wody.



Rys. 4.2.12. Wartości temperatury pobrane wzdłuż linii środkowej rzeki tylko z obrazów dewignetowanych (lewa kolumna), tylko z obrazów zoptymalizowanych (środkowa kolumna) oraz z obrazów dewignetowanych i zoptymalizowanych (prawa kolumna) wykreślone jako małe czerwone punkty. Duże niebiesko-zielono-żółte punkty wskazują temperaturę próbkowaną z nieprzetworzonych obrazów, a same kolory wyznaczają czas lotu w minutach. Linia przerywana wskazuje rzeczywistą temperaturę wody zmierzoną za pomocą termopary. Wiersze od A do E odpowiadają lokalizacjom (tab. 3.2.1.) (Szostak i in., 2023).

Dane

Dane przedstawione w niniejszym badaniu są publicznie dostępne w repozytorium Zenodo pod adresem <https://doi.org/10.5281/zenodo.8359964> (dostęp 29 września 2023). Kod źródłowy implementacji w Pythonie jest dostępny w formie notatników Jupyter w repozytorium

GitHub pod adresem <https://github.com/radekszostak/aerial-thermal-tuner> (dostęp 29 września 2023).

Wnioski

Zaproponowane rozwiązanie poprawiło precyzję pomiaru temperatury powierzchni wody za pomocą zdjęć termowizyjnych BSP. Spośród przetestowanych rozwiązań największy wpływ miała optymalizacja spójności temperatury pomiędzy przekrywającymi się obrazami. Korekcja winietowania pojedynczego obrazu, będąca drugim testowanym rozwiązaniem miała marginalny wpływ na ostateczne wyniki, co potwierdziło wspomniane w opisie metody spostrzeżenie, że natura użytego algorytmu typu *single image* nie pozwala na uzyskanie wystarczająco niezawodnych rezultatów.

Kalibracja bazująca na optymalizacji spójności między przekrywającymi się zdjęciami wyeliminowała odchylenie pomiarów wykonanych podczas początkowego etapu lotu, które wynikało z początkowo nieustabilizowanej temperatury wewnętrznych komponentów kamery. Zaproponowane podejście kalibracyjne sprawia więc że rozgrzewanie kamery przed lotem nie jest już konieczne.

Poprzednie metody redukcji niekorzystnych zjawisk występujących w niechłodzonych kamerach termowizyjnych opierały się na kalibracji w kontrolowanych warunkach laboratoryjnych i wymagały niestandardowego oprzyrządowania, takiego jak referencyjne ciała doskonale czarne lub własnoręcznie zbudowany osprzęt do BSP. Wymagają one dodatkowego wysiłku wyspecjalizowanego operatora i nie mogą być zautomatyzowane. W przeciwieństwie do poprzednich metod, zaproponowany algorytm wymaga jedynie danych zebranych podczas standardowego lotu BSP. Jest też wysoce zautomatyzowany, dzięki czemu może być uruchamiany przez osobę bez specjalistycznej wiedzy. Przedstawione czynniki sprawiają, że rozwiązanie jest możliwe do wdrożenia np. jako część cyklu pracy oprogramowania fotogrametrycznego.

Zaproponowana metoda została z powodzeniem przetestowana w zróżnicowanym krajobrazie małych dolin rzecznych na obszarach wiejskich i podmiejskich, gdzie naturalne i antropogeniczne pokrycia terenu przeplatają się z obszarami wód powierzchniowych o niejednorodnych temperaturach. Wiarygodne mapowanie temperatury powierzchni ziemi i wody w takich warunkach jest ważne dla zrozumienia interakcji wód gruntowych i powierzchniowych oraz innych procesów fizycznych, które wpływają na ekosystemy rzeczne.

Pomimo sukcesów tutaj opisanego pilotażowego eksperymentu należy mieć na uwadze jego ograniczenia i ewentualną możliwość jego udoskonalenia. Algorytm ten przede wszystkim

zwiększa dokładność pomiarów temperatury z początkowych faz lotu BSP poprzez dopasowanie ich do bardziej dokładnych pomiarów z późniejszych faz lotu. Nie jest on jednak w stanie poprawić ewentualnego stałego odchylenia wartości temperatury dla całej mozaiki. Tego typu błąd należy korygować poprzez dopasowanie całej mozaiki do punktowych referencyjnych pomiarów co również zostało opisane w tej rozprawie, jednak nie jest stricte częścią zaproponowanego algorytmu. Zaproponowana implementacja algorytmu może wymagać również optymalizacji poprzez na przykład użycie niskopoziomowego języka programowania.


4.3. Wyniki szacowania ewapotranspiracji na podstawie termografii BSP

Pomiary referencyjne kowariancją wirów

Część danych, głównie nocnych, została odrzucona z powodu niespełnienia warunków metodycznych, takich jak stacjonarność oraz obecność warunków turbulencyjnych (Foken i in., 2005). Z uwagi na krótki okres pomiarów, dane dotyczące niskiej prędkości wiatru nie zostały odrzucone. Po analizie jakości danych pozostało: 78% danych dotyczących strumienia ciepła jawnego, 75% dotyczących ciepła utajonego.


W czasie kampanii dominowały warunki chwiejne, występujące przez 82% czasu w ciągu dnia i 55% w nocy. W pozostałych okresach równowaga była stabilna. W trzech przypadkach, w sobotę, znacznie większe wartości bezwzględne długości Obuchowa wskazywały na stratyfikację bliską neutralnej, co miało miejsce w czasie zaniku termiki przed zachodem słońca. Średnia prędkość wiatru wynosiła przeważnie poniżej 2 m/s, a jego kierunek był głównie południowo-zachodni. W ciągu dnia prędkość i porywistość wiatru były większe z powodu termiki, natomiast w nocy były mniejsze. W sobotę przed zachodem słońca prędkość i porywistość wiatru malały, co zbiegło się w czasie z obserwowanymi zmianami w warunkach stratyfikacji, mierzonymi długością Obuchowa.

Dla celów analizy wyników metody kowariancji wirów zidentyfikowano dwa rodzaje roślinności: na południe od masztu znajduje się trawa i rzeka Kocinka, natomiast na północ – pole owsa. Obszar źródłowy został określony na podstawie modelu zaproponowanego przez (Kljun i in., 2015). Mimo że spełnione zostały warunki stacjonarności i występowania turbulencji, dla 76% półgodzinnych przedziałów czasowych model określania obszaru źródłowego nie mógł zostać zastosowany z powodu zbyt niskiej prędkości wiatru (prędkość tarciowa $u^* < 0.2$ m/s). Uśredniony obszar źródłowy, jaki udało się uzyskać na podstawie punktów, dla których dane spełniały warunki użycia w modelu, przedstawiono na rys. 4.3.1.



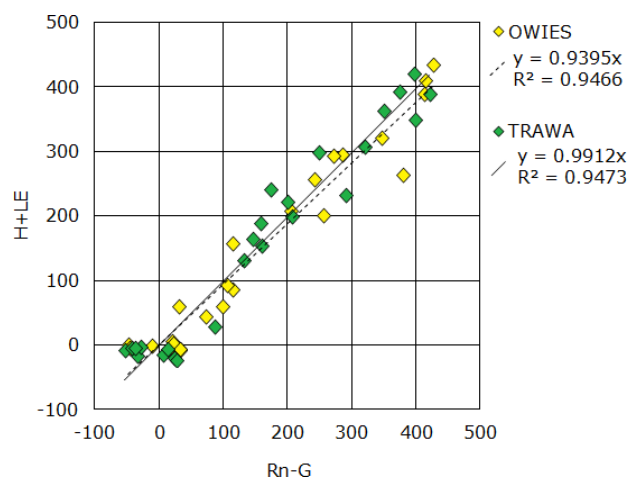
Rys. 4.3.1. Izolinie obszaru źródłowego (%) z zaznaczoną lokalizacją masztu (X). Izolinia o wartości $n\%$ wskazuje, że z obszaru przez nią objętego pochodzi $n\%$ obserwowanego strumienia. Podkład mapowy: Google (2023).

W celu przeprowadzenia analizy strumieni, dokonano rozdziału danych według dwóch typów pokrycia terenu, uwzględniając kierunek wiatru jako kryterium podziału. Przeważająca część sygnału pochodziła z kierunku 250° , co zostało potwierdzone analizą róży wiatrów. Obszar ten znajduje się na granicy pomiędzy trawą a polem, co sugeruje, że różnice pomiędzy tymi typami pokrycia terenu mogą być słabo widoczne.



Rys. 4.3.2. Przebieg czasowy składników bilansu energetycznego: H – ciepło jawne, LE – ciepło utajone, Rn – radiacyjny strumień przychodzący netto (promieniowanie długofalowe i krótkofalowe), G – strumień ciepła do gleby. Turbulencyjne strumienie (H i LE) z podziałem na obszar źródłowy.

Zgromadzone dane (rys. 4.3.2) pomiarowe umożliwiły weryfikację spełnienia bilansu energetycznego powierzchni (rys. 4.3.3). W warunkach idealnych zależność między sumą strumieni ciepła jawnego i utajonego ($H + LE$) a różnicą promieniowania netto i strumienia ciepła do gleby ($R_n - G$) powinna mieć charakter liniowy, z przecięciem w punkcie zerowym oraz współczynnikiem nachylenia równym 1.



Rys. 4.3.3. Bilans energetyczny: zależność sumy strumieni turbulencyjnych ciepła jawnego i utajonego ($H+LE$) od dostępnej energii radiacyjnej (R_n-G) dla powierzchni trawiastych i uprawy owsa. Idealne domknięcie bilansu energetycznego odpowiada linii o nachyleniu $y=x$. Wartości na osiach wyrażone w watach na metr kwadratowy (W/m^2).

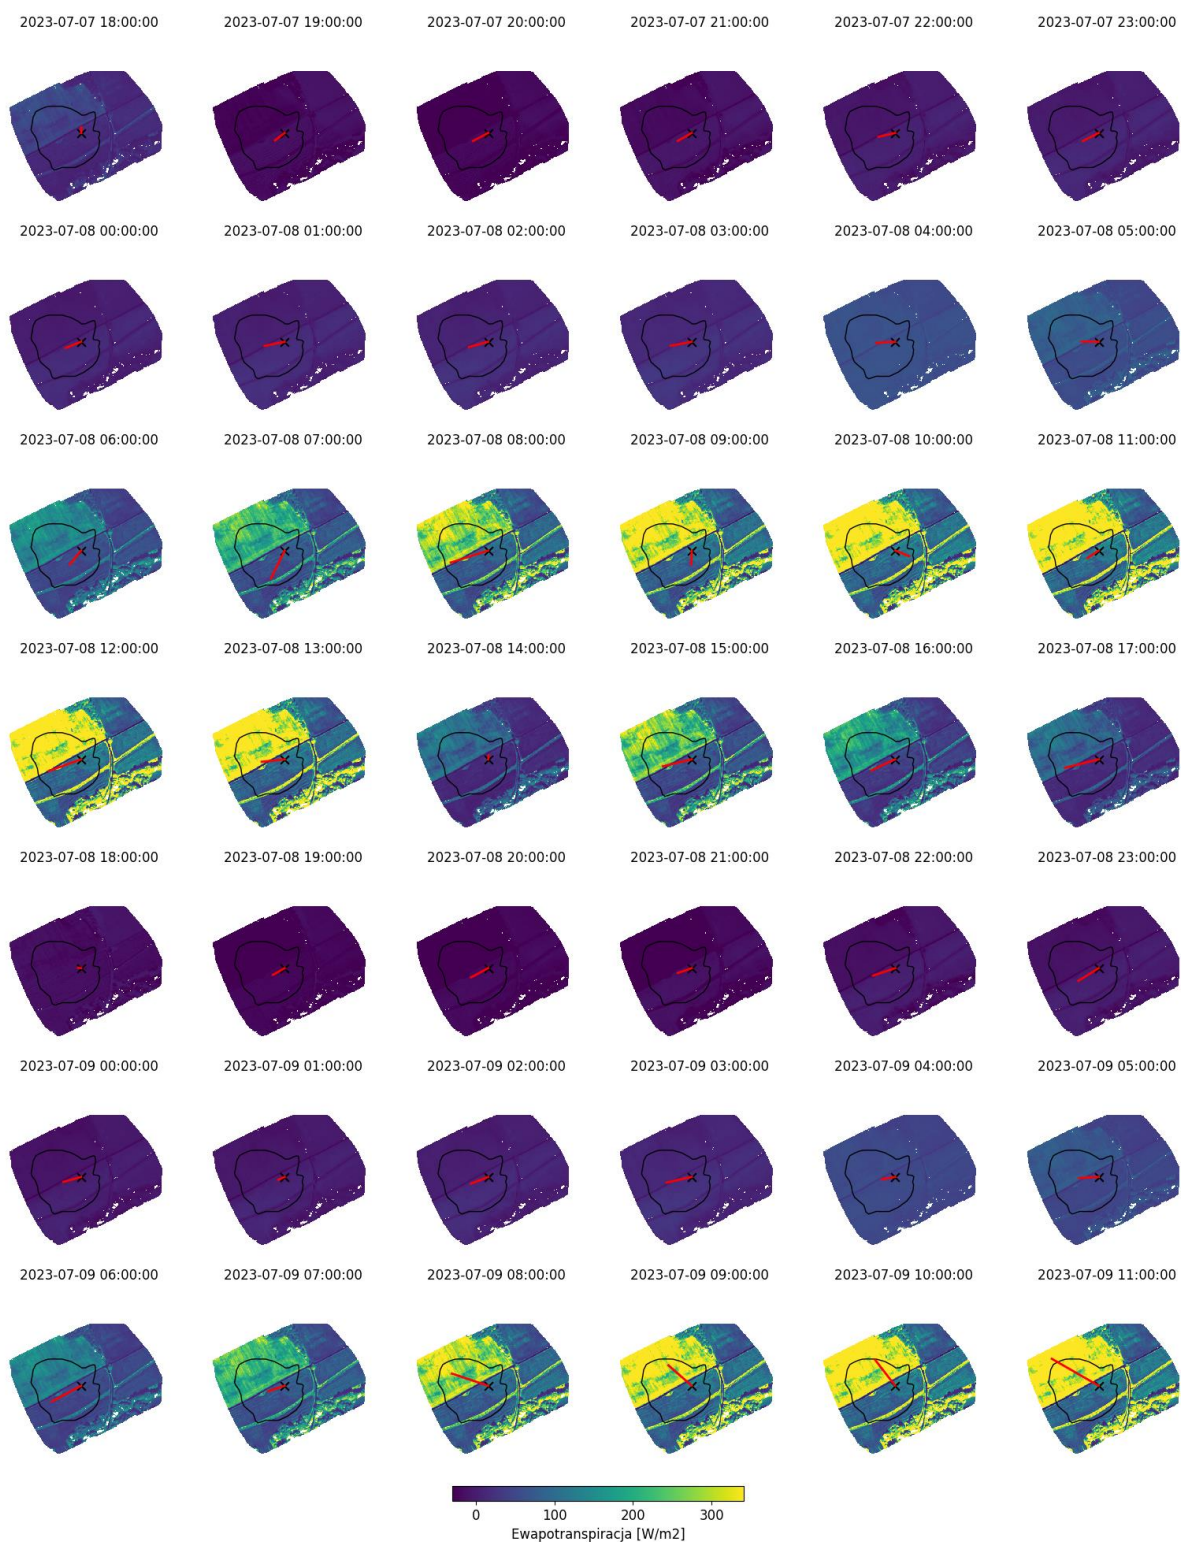
Bilans energetyczny został zamknięty na poziomie znacznie wyższym niż można było się spodziewać. W standardowych pomiarach techniką kowariancji wirów domknięcie bilansu osiąga zazwyczaj około 80%. Główna przyczyna niedomknięcia bilansu energetycznego wynika prawdopodobnie z systematycznego niedoszacowania strumieni ciepła jawnego (H) oraz strumieni ciepła utajonego (LE), co jest związane z adwekcją. W badanym przypadku składowa adwekcyjna wydaje się być nieznaczna, co można tłumaczyć niskimi prędkościami wiatru. W efekcie bilans energetyczny został zamknięty na wyższym niż oczekiwany poziomie, wynoszącym 94% dla owsa i 99% dla trawy.

Adaptacja PT-JPL

W wyniku adaptacji algorytmu PT-JPL opisanej w rozdziale 3.3, uzyskano serię rastrów przedstawiających ewapotranspirację z powierzchni badanego obszaru. Maksymalna rozdzielczość przestrzenna uzyskanych rastrów ewapotranspiracji uzależniona jest od najgorszej rozdzielczości spośród rastrów termograficznych i multispektralnych użytych do obliczeń. Pomimo możliwości uzyskania 9 cm piksela ewapotranspiracji (rozdzielczość danych termograficznych), użyto piksela o rozmiarze 20 cm. Podyktowane to było ograniczeniami pamięci komputera. Rozdzielczość czasowa wyników uzależniona jest od okresu nalołów

termograficznych. W tych badaniach było to ok. 3 godziny, jednak dzięki interpolacji metodą splines w ostateczności uzyskano dane o półgodzinnym okresie.

Wizualizacje uzyskanych rastrów ewapotranspiracji dla każdej pełnej godziny przedstawiono na rys. 4.3.4.




Rys. 4.3.4. Wizualizacje rastrów ewapotranspiracji uzyskanych metodą PT-JPL dla pełnych godzin zegarowych. Obrys wykonany czarną linią wyznacza rejestrowany obszar pomiaru metodą kowariancji wirów. Czarny znak „x” wyznacza pozycję wieży pomiarowej. Czerwona linia wyznacza kierunek, z którego wieje wiatr i jej długość jest proporcjonalna do szybkości wiatru. Jako referencję długości tej linii można wykorzystać ostatni rysunek, w którym prędkość wiatru wynosiła 2.5 m/s.

Uzyskane wyniki w postaci przestrzennej dystrybucji ewapotranspiracji pozwalają pomiar oddzielny dla różnych rodzajów powierzchni. W tych badaniach obliczono średnią

ewapotranspirację dla obszarów pola uprawnego z owsem, lasu, łąki, drogi oraz niewielkiego rozlewiska rzeki. Próbkowane obszary przedstawiono na rys. 4.3.5. Przebiegi czasowe ewapotranspiracji uśrednione przestrzenie po wspomnianych obszarach przedstawiono na rys. 4.3.6.




Rys. 4.3.5. Obszary użyte do przestrzennego uśrednienia ewapotranspiracji dla poszczególnych typów powierzchni.



Rys. 4.3.6. Przebiegi czasowe ewapotranspiracji uśrednionej przestrzennie po różnych rodzajach powierzchni.

Zauważalnym detalem na rys. 4.3.6 jest nagły spadek wartości ewapotranspiracji w dniu pierwszym. Spowodowany jest on tymczasowym wystąpieniem zachmurzenia, co potwierdza odczyt przychodzącego promieniowania krótkofalowego zarejestrowanych przy pomocy bilansomierza przedstawiony na rys. 4.3.7. Obserwowane drugiego dnia bardziej krótkotrwałe zachmurzenia miały o wiele mniejszy, jednak wciąż zauważalny wpływ na uzyskane szacowania ewapotranspiracji.

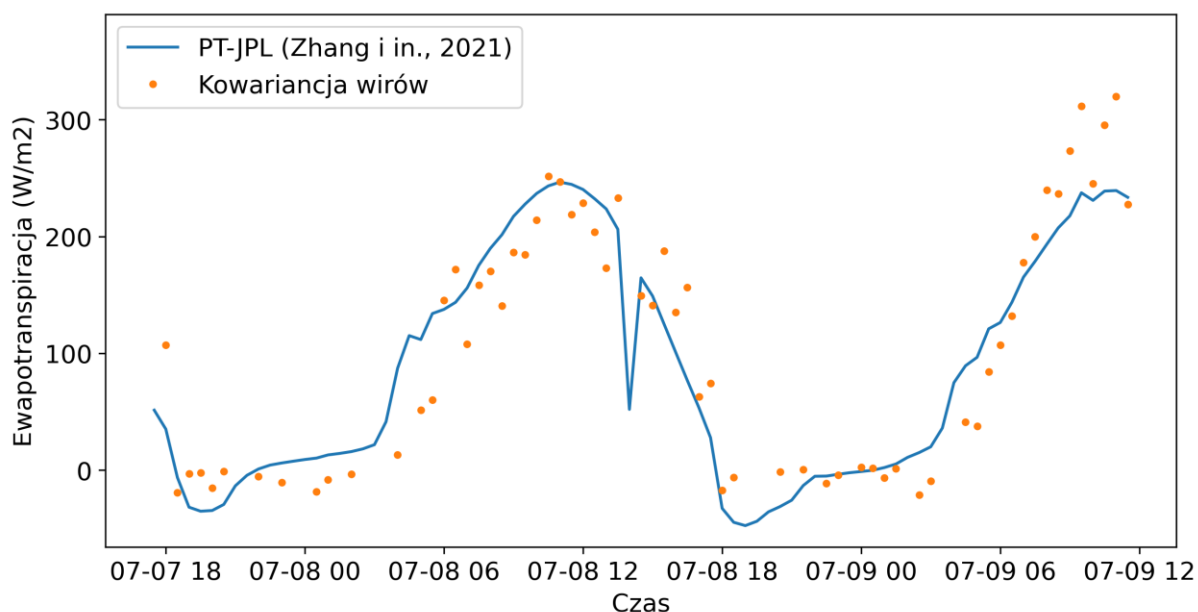


Rys. 4.3.7. Odczyty przychodzącego promieniowania krótkofalowego zarejestrowane przy pomocy bilansomierza.

Zamodelowane na rys. 4.3.6 przebiegi czasowe ewapotranspiracji mają cechy, które uzasadnić można dodatkowymi informacjami terenowymi. W przypadku uprawy owsa obserwujemy najwyższe zamodelowane wartości ewapotranspiracji spośród próbkowanych rodzajów powierzchni terenu. Pomiar wykonywany był w optymalnym okresie jego wzrostu, więc zawierał w sobie duże ilości wody, co uzasadnia wysokie odczyty. Przeciwną sytuację niskiej ewapotranspiracji zaobserwowano dla drogi. Jedyne znaczące wartości ewapotranspiracji z jej powierzchni występują nad ranem, kiedy skondensowana na niej rosa nocna zasilala proces parowania. Bezpośrednia ekspozycja na słońce i wysokie temperatury powietrza sprawiały, że droga szybko się wysuszała i w dalszych częściach dnia parowanie zanikało, co obserwujemy na przebiegu czasowym. Nieco wyższą niż dla drogi, jednak wciąż ograniczoną ewapotranspirację obserwowano dla łąki. Była ona skoszona, przez co w przeważającej części ekspozowała ona bezpośrednio grunt. Odczyty dla rzeki cechowały się znaczącym, jednak wciąż niższym tempem ewapotranspiracji niż dla owsa. Nie powinno się jednak polegać na tym odczycie, ponieważ algorytm PT-JPL jest niezdefiniowany dla zbiorników wód powierzchniowych. Niższe niż dla owsa odczyty dla lasu można uzasadnić jego dojrzalszym etapem wzrostu liści niż dla rozwijającego się jeszcze owsa.

Porównanie wyników obu metod

Porównanie jednowymiarowych (czas) danych z metody kowariancji wirów z trójwymiarowymi (czas, położenie x, położenie y) danymi rastrowymi PT-JPL wykonano poprzez uśrednienie rastrów PT-JPL po obszarze rejestrowanym metodą kowariancji wirów, co sprowadziło je do danych w jednym wymiarze czasu. W wyniku przeprowadzonego eksperymentu uzyskano 64 pary wartości ewapotranspiracji uzyskanych metodą kowariancji wirów i PT-JPL. Wyniki porównania przedstawiono na rys. 4.3.8. Uznając wyniki z metody kowariancji wirów za wzorcowe, obliczono również metryki błędu metody PT-JPL: $RMSE = 37.41 \text{ W/m}^2$, $MAE = 30.27 \text{ W/m}^2$, $MBE = -0.27 \text{ W/m}^2$ oraz $R^2 = 0.87$.



Rys. 4.3.8. Przebieg czasowy ewapotranspiracji z obszaru rejestrowanego w metodzie kowariancji wirów – porównanie metody PT-JPL z kowariancją wirów

Na podstawie jakościowej analizy wykresu X można stwierdzić, że pomiary zaadaptowaną metodą PT-JPL są zbliżone do referencyjnych pomiarów metodą kowariancji wirów. Potwierdza to również wysoka wartość współczynnika determinacji R^2 .

Wnioski

W przeprowadzonym eksperymencie metoda PT-JPL dobrze odwzorowała wyniki uzyskane za pomocą metody kowariancji wirów podczas dwudniowej kampanii pomiarowej. Należy jednak pamiętać, że badania przeprowadzono tylko w jednym typie krajobrazu, w stabilnych, słonecznych i ciepłych warunkach pogodowych. Ogranicza to możliwość wnioskowania o skuteczności metody w innych typach krajobrazu lub przy różnych warunkach atmosferycznych.

Szacowanie przestrzennego rozkładu ewapotranspiracji na podstawie danych teledetekcyjnych jest obiecującą metodą, która stwarza nowe możliwości badawcze. W zaprezentowanym eksperymencie umożliwiła ona oszacowanie ewapotranspiracji dla kilku rodzajów powierzchni, które nie były objęte zasięgiem metody kowariancji wirów i które nie mogły być zmierzone za pomocą metod satelitarnych z powodu niewystarczającej rozdzielczości przestrzennej i czasowej.

5. Podsumowanie

Metody rozwinięte w ramach pracy mają związek z badaniem i monitoringiem różnych aspektów cyklu hydrologicznego w dolinach rzecznych. Określenie bilansu wodnego rzek jest kluczowym zagadnieniem zarządzania zasobami wodnymi w zlewniach rzecznych, tymczasem istotne jego składniki są słabo poznane. Dotyczy to np. interakcji wód powierzchniowych z podziemnymi i ze strefami przybrzeżnymi koryta, wielkości ewapotranspiracji w dnach dolin. Metody zaproponowane i praktycznie sprawdzone w niniejszej pracy mają bezpośrednie zastosowanie w jakościowym i ilościowym rozpoznaniu powyższych procesów dla obszarów pokrywanych przez loty BSP, a więc rzędu dziesiątek hektarów. Rozwijając te metody interdyscyplinarne podejście, łączące technologie BSP, teledetekcję oraz zaawansowane techniki analizy danych, w tym uczenie maszynowe. Czynnikiem łączącym metody rozwinięte w niniejszej pracy jest zastosowanie nowoczesnych technik umożliwiających akwizycję, przetwarzanie i syntezę dużych zbiorów danych pochodzących z teledetekcji i innych źródeł. Niniejsza praca wpisuje się więc w trendy nowoczesnej hydrologii, której metody coraz szerzej opierają się na wykorzystaniu dużych zbiorów danych obserwacyjnych o dużej rozdzielczości przestrzennej i czasowej.

Pierwszy projekt opisany w rozprawie dotyczył rozwiązania problemu zaburzeń w fotogrametrycznych numerycznych modelach pokrycia terenu na obszarach małych strumieni. Wykorzystano w nim metody sztucznej inteligencji do oszacowania poziomu wody na podstawie danych fotogrametrycznych. Rozwiązanie opierało się na niestandardowej splotowej sieci neuronowej, wytrenowanej przy użyciu specjalnie opracowanej funkcji straty. Dane pochodziły z pięciu studiów przypadków. Zaproponowana metoda stanowi nowatorskie podejście, które nie było wcześniej opisane w literaturze. Osiąga ona znacznie wyższą dokładność w szacowaniu poziomu wody w małych rzekach w porównaniu z tradycyjnymi metodami, opartymi na bezpośrednim próbkowaniu fotogrametrycznych modeli terenu. Wyniki te potwierdzają tezę postawioną we wstępie, że zastosowanie uczenia maszynowego pozwala zwiększyć dokładność odczytu poziomu wody z fotogrametrycznego modelu terenu stworzonego z danych z BSP. Dodatkowo, opracowane rozwiązanie cechuje się precyzją porównywalną z najlepszymi dostępnymi metodami wykorzystującymi BSP. Wyniki tej metody zostały już opublikowane (Szostak i in., 2024).

Drugi projekt opisany w rozprawie dotyczył problemu niedostatecznej dokładności pomiaru temperatury przy użyciu niechłodzonych kamer termowizyjnych zamontowanych na BSP. Błąd pomiarowy wynikał m.in. z dryfu spowodowanego nagrzewaniem się kamery podczas lotu. W ramach pracy doktorskiej opracowano metodę redukcji tego dryfu poprzez kalibrację, która nie

wymaga laboratoryjnych danych kalibracyjnych, lecz opiera się wyłącznie na danych zebranych podczas lotu. Zrealizowano to poprzez minimalizację różnic temperatury pomiędzy nakładającymi się zdjęciami, wykorzystując optymalizację metodą gradientową oraz specjalnie opracowaną funkcję straty. Kluczowym elementem rozwiązania była georeferencja i wzajemne dopasowanie położeń zdjęć, również realizowane metodą gradientową, poprzez optymalizację parametrów macierzy przekształcenia przy użyciu dedykowanej funkcji straty. Zaproponowana metoda znacząco zwiększyła precyzję pomiaru temperatury ze zdjęć termowizyjnych oraz zmniejszyła odchylenie pomiarów wykonywanych w początkowej fazie lotu, spowodowane niestabilizowaną temperaturą wewnętrznych komponentów kamery. Dzięki temu podejściu rozgrzewanie kamery przed lotem nie jest już konieczne. Wyniki te potwierdzają tezę, że zastosowanie uczenia maszynowego może poprawić dokładność pomiaru temperatury terenu wykonanej za pomocą kamery termowizyjnej zamontowanej na BSP. Wyniki tej metody zostały już opublikowane (Szostak i in., 2023).

Trzeci projekt, zrealizowany w ramach rozprawy, polegał na weryfikacji możliwości adaptacji algorytmu PT-JPL, pierwotnie stworzonego do szacowania ewapotranspiracji na podstawie danych z satelitarnej misji ECOSTRESS, do obliczania ewapotranspiracji na podstawie pomiarów wykonanych przy użyciu BSP. Eksperyment trwał dwa dni, podczas których zbierano dane za pomocą BSP oraz stacji meteorologicznej. Uzyskane dane posłużyły do obliczenia ewapotranspiracji z wykorzystaniem zaadaptowanego algorytmu PT-JPL oraz metody kowariancji wirów, która posłużyła jako pomiar referencyjny. Wyniki szacowań za pomocą zaadaptowanej metody wykazały zgodność z pomiarami referencyjnymi, co pozwoliło na wstępne potwierdzenie, że algorytm PT-JPL może być stosowany do pomiarów realizowanych przy pomocy BSP. Choć eksperyment obejmował ograniczoną liczbę punktów pomiarowych, można wstępnie potwierdzić hipotezę, że metoda PT-JPL może być stosowana do szacowania rozkładu ewapotranspiracji na podstawie danych z BSP. Publikacja dla tej metody jest w trakcie tworzenia.

Podsumowanie oryginalnego wkładu autora

Spośród treści przedstawionych w niniejszej rozprawie, następujące działania stanowią oryginalny wkład autora. Począwszy od projektu szacowania poziomu wody małych strumieni przy pomocy fotogrametrii BSP i uczenia głębokiego, można wymienić poniższe oryginalne elementy.

- Przeprowadzenie czterech kampanii pomiarowych w dolinie rzeki Kocinka, podczas których wykonano naloty fotogrametryczne przy pomocy BSP, wyznaczono

fotogrametryczne punkty referencyjne, oraz dokonano wzorcowych pomiarów poziomu wody w rzece.

- Dla każdej z czterech kampanii pomiarowych wygenerowanie fotogrametrycznych mozaik NMPT i ortofotomap na podstawie zebranych zdjęć lotniczych i punktów referencyjnych.
- Zaadaptowanie danych pozyskanych przez innych badaczy, w celu suplementacji zbioru danych użytego w eksperymencie.
- Opracowanie zbioru danych przeznaczonego do treningu modelu uczenia maszynowego. Prace te obejmowały wytyczenie linii wzdłuż środków i brzegów rzek, wycięcie próbek z wielkoformatowych rastrów NMPT oraz ortofotomapy, przypisanie próbkom wzorcowych wartości poziomu wody w rzece i innych metadanych. Jest to niespotykany wcześniej w literaturze przypadek przygotowania tego typu zbioru danych uczenia maszynowego.
- Opracowanie różnych wariantów modeli uczenia maszynowego przeznaczonych do przewidywania poziomu powierzchni wody w rzece. Jest to niespotykana wcześniej w literaturze metoda szacowania poziomu wody w rzece. Na szczególną uwagę zasługuje model działający poprzez uśrednianie maski, który został stworzony specjalnie na potrzeby tego problemu badawczego. Cechuje się nieszablonowym podejściem i autorską funkcją straty. Wedle najlepszej wiedzy, tego typu podejście nie było też wcześniej stosowane w innych dziedzinach nauki związanych z analizą obrazów.
- Wykonanie wyszukiwania siatki w celu znalezienia optymalnych hiperparametrów testowanych modeli. W ramach samego wyszukiwania siatki opisanego w rozprawie wykonano w 750 treningów odpowiadających różnym modelom, hiperparametrom, podzbiorom walidującym i rodzajom walidacji krzyżowej. Przed tym wykonano także szereg treningów podczas opracowywania docelowych modeli. Biorąc to pod uwagę szacunkowa ilość wszystkich treningów wykonanych w ramach doktoratu wynosi około 1500.
- Porównanie zaproponowanego rozwiązania z istniejącymi metodami wykorzystującymi BSP do szacowania poziomu wody w małych rzekach.

Autorskie działania wykonane w ramach projektu automatycznej kalibracji lotniczych obrazów termowizyjnych przy użyciu optymalizacji metodą gradientów są następujące.

- Wykonanie laboratoryjnych badań dokładności pomiaru temperatury przy pomocy niechłodzonej kamery termowizyjnej.
- Zrealizowanie pięciu kampanii pomiarowych podczas których wykonano termograficzne zdjęcia lotnicze dolin rzek przy pomocy BSP i dokonano referencyjnych punktowych pomiarów temperatury wody.
- Adaptacja algorytmu korekcji efektu winiety w celu użycia na zdjęciach termowizyjnych.
- Adaptacja algorytmu pierwotnie opracowanego do łączenia zdjęć lotniczych, uzupełniając go o bezpośrednią georeferencję.
- Opracowanie algorytmu kalibracji poprzez optymalizację spójności odczytów temperatury między przekrywającymi się zdjęciami termowizyjnymi. Dla potrzeb algorytmu opracowano dedykowaną funkcję straty. Jest to pierwsze tego typu podejście gdzie optymalizacja metodą gradientów została użyta do takiego celu.
- Walidacja algorytmu na podstawie pomiarów referencyjnych.

Autorski wkład w projekcie szacowania ewapotranspiracji na podstawie termografii BSP obejmuje następujące czynności.

- W trakcie dwudniowej kampanii pomiarowej przeprowadzono jeden nalot BSP, w ramach którego wykonano zdjęcia multispektralne, oraz dwanaście nalotów, podczas których zarejestrowano obrazy termowizyjne.
- Równoległy do przeprowadzonych nalotów, pomiar szeregów czasowych danych meteorologicznych.
- Adaptacja modelu PT-JPL w celu użycia go z danymi zebranymi przy użyciu BSP.
- Porównanie rezultatów zaadaptowanego modelu PT-JPL z pomiarami kowariancją wirów.

Indeks skrótów

AET	actual evapotranspiration
ANN	artificial neural network
BSP	bezzałogowy statek powietrzny
CNN	convolutional neural networks
DNN	deep neural networks
DSM	digital surface model
ECOSTRESS	Ecosystem Spaceborne Thermal Radiometer Experiment on Space Station
ET	ewapotranspiracja
EVI	Enhanced Vegetation Index
EXIF	exchangeable image file format
FANN	fast approximate nearest neighbour
GC	gazy cieplarniane
GNSS	global navigation satellite system
GPS	global positioning system
HRMET	high resolution mapping of evapotranspiration
IMU	inertial measurement unit
LE	latent energy
LIDAR	light detection and ranging
m n.p.m.	metry nad poziomem morza
MAE	mean absolute error
MBE	mean bias error
METRIC	mapping evapotranspiration at high resolution with internalized calibration
ML	machine learning
MSE	mean square error
NDVI	Normalized Difference Vegetation Index
NMPT	numeryczny model pokrycia terenu
OSEB	one-source energy balance
PET	ewapotranspiracja potencjalna (ang. potential evapotranspiration)
PET	ewapotranspiracja potencjalna
PPK	post-processed kinematic
PT-JPL	Priestley-Taylor Jet Propulsion Laboratory
RANSAC	random sample consensus
RGB	red green blue
RMSE	root mean square error
RNN	recurrent neural networks
RTK	real-time kinematic
RTK	real-time kinematic
RTN	real-time network
SEBAL	surface energy balance algorithm for land
SIFT	scale-invariant feature transform
SLAM	simultaneous localisation and mapping
TSEB	two-source energy balance
UAV	unmanned aerial vehicle
UM	uczenie maszynowe
UTC	Universal Time Coordinated
UTM	Universal Transverse Mercator
VO	visual odometry

Bibliografia

- Abtew, W., & Melesse, A. (2013). *Evaporation and Evapotranspiration: Measurements and Estimations*. Springer Netherlands. <https://doi.org/10.1007/978-94-007-4737-1>
- Acharya, B. S., Bhandari, M., Bandini, F., Pizarro, A., Perks, M., Joshi, D. R., Wang, S., Dogwiler, T., Ray, R. L., Kharel, G., & Sharma, S. (2021). Unmanned Aerial Vehicles in Hydrology and Water Management: Applications, Challenges, and Perspectives. *Water Resources Research*, 57(11). <https://doi.org/10.1029/2021WR029925>
- Ahmad, N., Ghazilla, R. A. R., Khairi, N. M., & Kasi, V. (2013). Reviews on Various Inertial Measurement Unit (IMU) Sensor Applications. *International Journal of Signal Processing Systems*, 256–262. <https://doi.org/10.12720/ijsp.1.2.256-262>
- Allen, R., Pereira, L., Raes, D., & Smith, M. (1998). *Crop Evapotranspiration (guidelines for computing crop water requirements)*. *FAO Irrigation and Drainage Paper*, 56.
- Allen, R., Tasumi, M., & Trezza, R. (2007). Satellite-Based Energy Balance for Mapping Evapotranspiration with Internalized Calibration (METRIC)—Model. *Journal of Irrigation and Drainage Engineering*, 133(4), 380–394. [https://doi.org/10.1061/\(ASCE\)0733-9437\(2007\)133:4\(380\)](https://doi.org/10.1061/(ASCE)0733-9437(2007)133:4(380))
- Allouis, T., Bailly, J., Pastol, Y., & Le Roux, C. (2010). Comparison of LiDAR waveform processing methods for very shallow water bathymetry using Raman, near-infrared and green signals. *Earth Surface Processes and Landforms*, 35(6), 640–650. <https://doi.org/10.1002/esp.1959>
- Aragon, B., Johansen, K., Parkes, S., Malbeteau, Y., Al-Mashharawi, S., Al-Amoudi, T., Andrade, C. F., Turner, D., Lucieer, A., & McCabe, M. F. (2020). A Calibration Procedure for Field and UAV-Based Uncooled Thermal Infrared Instruments. *Sensors*, 20(11), 3316. <https://doi.org/10.3390/s20113316>
- Aubinet, M., Vesala, T., & Papale, D. (Red.). (2012). *Eddy Covariance: A Practical Guide to Measurement and Data Analysis*. Springer Netherlands. <https://doi.org/10.1007/978-94-007-2351-1>
- Balamurugan, G., Valarmathi, J., & Naidu, V. P. S. (2016). Survey on UAV navigation in GPS denied environments. *2016 International Conference on Signal Processing, Communication, Power and Embedded System (SCOPEs)*, 198–204. <https://doi.org/10.1109/SCOPEs.2016.7955787>
- Bandini, F., Jakobsen, J., Olesen, D., Reyna-Gutierrez, J. A., & Bauer-Gottwein, P. (2017). Measuring water level in rivers and lakes from lightweight Unmanned Aerial Vehicles. *Journal of Hydrology*, 548, 237–250. <https://doi.org/10.1016/j.jhydrol.2017.02.038>
- Bandini, F., Sunding, T. P., Linde, J., Smith, O., Jensen, I. K., Köppl, C. J., Butts, M., & Bauer-Gottwein, P. (2020). Unmanned Aerial System (UAS) observations of water surface elevation in a small stream: Comparison of radar altimetry, LIDAR and photogrammetry techniques. *Remote Sensing of Environment*, 237. <https://doi.org/10.1016/j.rse.2019.111487>
- Bastiaanssen, W. G. M., Menenti, M., Feddes, R. A., & Holtslag, A. A. M. (1998). A remote sensing surface energy balance algorithm for land (SEBAL). 1. Formulation. *Journal of Hydrology*, 212–213, 198–212. [https://doi.org/10.1016/S0022-1694\(98\)00253-4](https://doi.org/10.1016/S0022-1694(98)00253-4)

- Blume, T., Van Meerveld, I., & Weiler, M. (2016). The role of experimental work in hydrological sciences – insights from a community survey. *Hydrological Sciences Journal*, 1–4. <https://doi.org/10.1080/02626667.2016.1230675>
- Boehmer, N. A. (1996). Vegetation indices for Landsat images. *Proceeding of Southwest Symposium on Image Analysis and Interpretation*, 258–262. <https://doi.org/10.1109/IAI.1996.493763>
- Brenner, C., Thiem, C. E., Wizemann, H.-D., Bernhardt, M., & Schulz, K. (2017). Estimating spatially distributed turbulent heat fluxes from high-resolution thermal imagery acquired with a UAV system. *International Journal of Remote Sensing*, 38(8–10), 3003–3026. <https://doi.org/10.1080/01431161.2017.1280202>
- Brzank, A., Heipke, C., Goepfert, J., & Soergel, U. (2008). Aspects of generating precise digital terrain models in the Wadden Sea from lidar–water classification and structure line extraction. *ISPRS Journal of Photogrammetry and Remote Sensing*, 63(5), 510–528. <https://doi.org/10.1016/j.isprsjprs.2008.02.002>
- Bühler, Y., Adams, M. S., Stoffel, A., & Boesch, R. (2017). Photogrammetric reconstruction of homogenous snow surfaces in alpine terrain applying near-infrared UAS imagery. *International Journal of Remote Sensing*, 38(8–10), 3135–3158. <https://doi.org/10.1080/01431161.2016.1275060>
- Burba, G., & Anderson, D. (2010). *A Brief Practical Guide to Eddy Covariance Flux Measurements: Principles and Workflow Examples for Scientific and Industrial Applications*. <https://doi.org/10.13140/RG.2.1.1626.4161>
- Caniou, J. (1999). *Passive Infrared Detection*. Springer US. <https://doi.org/10.1007/978-1-4757-6140-5>
- Chabot, D. (2018). Trends in drone research and applications as the *Journal of Unmanned Vehicle Systems* turns five. *Journal of Unmanned Vehicle Systems*, 6(1), vi–xv. <https://doi.org/10.1139/juvs-2018-0005>
- Chawla, I., Karthikeyan, L., & Mishra, A. K. (2020). A review of remote sensing applications for water security: Quantity, quality, and extremes. *Journal of Hydrology*, 585, 124826. <https://doi.org/10.1016/j.jhydrol.2020.124826>
- Çiçek, Ö., Abdulkadir, A., Lienkamp, S. S., Brox, T., & Ronneberger, O. (2016). 3D U-Net: Learning Dense Volumetric Segmentation from Sparse Annotation. W. S. Ourselin, L. Joskowicz, M. R. Sabuncu, G. Unal, & W. Wells (Eds.), *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2016* (T. 9901, s. 424–432). Springer International Publishing. https://doi.org/10.1007/978-3-319-46723-8_49
- Collin, A., Archambault, P., & Long, B. (2008). Mapping the Shallow Water Seabed Habitat With the SHOALS. *IEEE Transactions on Geoscience and Remote Sensing*, 46(10), 2947–2955. <https://doi.org/10.1109/TGRS.2008.920020>
- Davie, T. (2019). *Fundamentals of hydrology* (Third Edition). Routledge, Taylor & Francis Group.
- Deng, J., Dong, W., Socher, R., Li, L.-J., Li, K., & Fei-Fei, L. (2009). ImageNet: A large-scale hierarchical image database. W *2009 IEEE Conference on Computer Vision and Pattern Recognition*. IEEE. <https://doi.org/10.1109/cvpr.2009.5206848>
- Falco, G., Pini, M., & Marucco, G. (2017). Loose and Tight GNSS/INS Integrations: Comparison of Performance Assessed in Real Urban Scenarios. *Sensors*, 17(2), 255. <https://doi.org/10.3390/s17020255>

- Fan, T., Wang, G., Li, Y., & Wang, H. (2020). MA-Net: A Multi-Scale Attention Network for Liver and Tumor Segmentation. *IEEE Access*, 8, 179656–179665. <https://doi.org/10.1109/ACCESS.2020.3025372>
- Fischler, M. A., & Bolles, R. C. (1981). Random sample consensus: A paradigm for model fitting with applications to image analysis and automated cartography. *Communications of the ACM*, 24(6), 381–395. <https://doi.org/10.1145/358669.358692>
- Fisher, J. B. (2018). *Level-3 Evapotranspiration L3(ET_PT-JPL) Algorithm Theoretical Basis Document*.
- Fisher, J. B., Tu, K. P., & Baldocchi, D. D. (2008). Global estimates of the land–atmosphere water flux based on monthly AVHRR and ISLSCP-II data, validated at 16 FLUXNET sites. *Remote Sensing of Environment*, 112(3), 901–919. <https://doi.org/10.1016/j.rse.2007.06.025>
- Foken, T. (2017). *Micrometeorology*. Springer Berlin Heidelberg. <https://doi.org/10.1007/978-3-642-25440-6>
- Foken, T., Göockede, M., Mauder, M., Mahrt, L., Amiro, B., & Munger, W. (2005). Post-Field Data Quality Control. W X. Lee, W. Massman, & B. Law (Red.), *Handbook of Micrometeorology* (T. 29, s. 181–208). Kluwer Academic Publishers. https://doi.org/10.1007/1-4020-2265-4_9
- Glenn, E. P., Huete, A. R., Nagler, P. L., & Nelson, S. G. (2008). Relationship Between Remotely-sensed Vegetation Indices, Canopy Attributes and Plant Physiological Processes: What Vegetation Indices Can and Cannot Tell Us About the Landscape. *Sensors*, 8(4), 2136–2160. <https://doi.org/10.3390/s8042136>
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.
- GPS Standard Positioning Service Performance Analysis Report*. (2021). William J. Hughes Technical Center WAAS Test Team. https://www.nstb.tc.faa.gov/reports/2020_Q4_SPS_PAN_v2.0.pdf
- Gu, L., Massman, W. J., Leuning, R., Pallardy, S. G., Meyers, T., Hanson, P. J., Riggs, J. S., Hosman, K. P., & Yang, B. (2012). The fundamental equation of eddy covariance and its application in flux measurements. *Agricultural and Forest Meteorology*, 152, 135–148. <https://doi.org/10.1016/j.agrformet.2011.09.014>
- Guenther, G., Cunningham, A., LaRocque, P., & Reid, D. (2000). Meeting the accuracy challenge in airborne Lidar bathymetry. *Proceedings of EARSeL-SIG-Workshop LIDAR, 1*.
- Haddeland, I., Heinke, J., Biemans, H., Eisner, S., Flörke, M., Hanasaki, N., Konzmann, M., Ludwig, F., Masaki, Y., Schewe, J., Stacke, T., Tessler, Z. D., Wada, Y., & Wisser, D. (2014). Global water resources affected by human interventions and climate change. *Proceedings of the National Academy of Sciences*, 111(9), 3251–3256. <https://doi.org/10.1073/pnas.1222475110>
- He, K., Zhang, X., Ren, S., & Sun, J. (2015). *Deep Residual Learning for Image Recognition*. <https://doi.org/10.48550/ARXIV.1512.03385>
- Hillel, D., & Warrick, A. W. (2009). *Environmental soil physics* (Nachdr. der Ausg. 1998). AP, Acad. Press.

- Hirabayashi, Y., Mahendran, R., Koirala, S., Konoshima, L., Yamazaki, D., Watanabe, S., Kim, H., & Kanae, S. (2013). Global flood risk under climate change. *Nature Climate Change*, 3(9), 816–821. <https://doi.org/10.1038/nclimate1911>
- Hoffmann, H., Nieto, H., Jensen, R., Guzinski, R., Zarco-Tejada, P., & Friborg, T. (2016). Estimating evaporation with thermal UAV data and two-source energy balance models. *Hydrology and Earth System Sciences*, 20(2), 697–713. <https://doi.org/10.5194/hess-20-697-2016>
- Höfle, B., Vetter, M., Pfeifer, N., Mandlbürger, G., & Stötter, J. (2009). Water surface mapping from airborne laser scanning using signal intensity and elevation data. *Earth Surface Processes and Landforms*, 34(12), 1635–1649. <https://doi.org/10.1002/esp.1853>
- Huang, L. Y. (2020). *luna983/stitch-aerial-photos: Stable v1.1* (Wersja v1.1) [Software]. Zenodo. <https://doi.org/10.5281/zenodo.4009830>
- Huss, M., Bookhagen, B., Huggel, C., Jacobsen, D., Bradley, R. S., Clague, J. J., Vuille, M., Buytaert, W., Cayan, D. R., Greenwood, G., Mark, B. G., Milner, A. M., Weingartner, R., & Winder, M. (2017). Toward mountains without permanent snow and ice. *Earth's Future*, 5(5), 418–435. <https://doi.org/10.1002/2016EF000514>
- Iakubovskii, P. (2019). Segmentation Models Pytorch. W *GitHub repository*. GitHub. https://github.com/qubvel/segmentation_models.pytorch
- IPCC. (2018). *Global Warming of 1.5°C: IPCC Special Report on Impacts of Global Warming of 1.5°C above Pre-industrial Levels in Context of Strengthening Response to Climate Change, Sustainable Development, and Efforts to Eradicate Poverty* (1. wyd.). Cambridge University Press. <https://doi.org/10.1017/9781009157940>
- IPCC. (2023). *IPCC, 2023: Climate Change 2023: Synthesis Report. Contribution of Working Groups I, II and III to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change [Core Writing Team, H. Lee and J. Romero (eds.)]*. IPCC, Geneva, Switzerland. (First). Intergovernmental Panel on Climate Change (IPCC). <https://doi.org/10.59327/IPCC/AR6-9789291691647>
- Javernick, L., Brasington, J., & Caruso, B. (2014). Modeling the topography of shallow braided rivers using Structure-from-Motion photogrammetry. *Geomorphology*, 213, 166–182. <https://doi.org/10.1016/j.geomorph.2014.01.006>
- Kasvi, E., Salmela, J., Lotsari, E., Kumpula, T., & Lane, S. N. (2019). Comparison of remote sensing based approaches for mapping bathymetry of shallow, clear water rivers. *Geomorphology*, 333, 180–197. <https://doi.org/10.1016/j.geomorph.2019.02.017>
- Kelly, J., Kljun, N., Olsson, P.-O., Mihai, L., Liljeblad, B., Weslien, P., Klemedtsson, L., & Eklundh, L. (2019). Challenges and Best Practices for Deriving Temperature Data from an Uncalibrated UAV Thermal Infrared Camera. *Remote Sensing*, 11(5), 567. <https://doi.org/10.3390/rs11050567>
- Kljun, N., Calanca, P., Rotach, M. W., & Schmid, H. P. (2015). A simple two-dimensional parameterisation for Flux Footprint Prediction (FFP). *Geoscientific Model Development*, 8(11), 3695–3713. <https://doi.org/10.5194/gmd-8-3695-2015>
- Kratzert, F., Klotz, D., Herrnegger, M., Sampson, A. K., Hochreiter, S., & Nearing, G. S. (2019). Toward Improved Predictions in Ungauged Basins: Exploiting the Power of Machine Learning. *Water Resources Research*, 55(12), 11344–11354. <https://doi.org/10.1029/2019WR026065>

- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). ImageNet Classification with Deep Convolutional Neural Networks. W F. Pereira, C. J. Burges, L. Bottou, & K. Q. Weinberger (Eds.), *Advances in Neural Information Processing Systems* (T. 25). Curran Associates, Inc.
https://proceedings.neurips.cc/paper_files/paper/2012/file/c399862d3b9d6b76c8436e924a68c45b-Paper.pdf
- Kusnierek, K., & Korsath, A. (2014). Challenges in using an analog uncooled microbolometer thermal camera to measure crop temperature. *International Journal of Agricultural and Biological Engineering*.
- Lawford, R., Strauch, A., Toll, D., Fekete, B., & Cripe, D. (2013). Earth observations for global water security. *Current Opinion in Environmental Sustainability*, 5(6), 633–643. <https://doi.org/10.1016/J.COSUST.2013.11.009>
- Lin, D., Maas, H.-G., Westfeld, P., Budzier, H., & Gerlach, G. (2018). An advanced radiometric calibration approach for uncooled thermal cameras. *Photogrammetric Record*. <https://doi.org/10.1111/phor.12216>
- Lowe, D. G. (2004). Distinctive Image Features from Scale-Invariant Keypoints. *International Journal of Computer Vision*, 60(2), 91–110.
<https://doi.org/10.1023/B:VISI.0000029664.99615.94>
- Mandl, F. (2013). *Statistical Physics* (2nd ed). Wiley.
- Mandlbauer, G., Pfennigbauer, M., Wieser, M., Riegl, U., & Pfeifer, N. (2016). EVALUATION OF A NOVEL UAV-BORNE TOPO-BATHYMETRIC LASER PROFILER. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, XLI-B1*, 933–939. <https://doi.org/10.5194/isprs-archives-XLI-B1-933-2016>
- Mesas-Carrascosa, F. J., Pérez-Porras, F. J., Larriva, J. E. M. de, Frau, C. M., Agüera-Vega, F., Carvajal-Ramírez, F., Martínez-Carricondo, P., & García-Ferrer, A. (2018). Drift Correction of Lightweight Microbolometer Thermal Sensors On-Board Unmanned Aerial Vehicles. *Remote Sensing*. <https://doi.org/10.3390/rs10040615>
- Mishra, A. K., & Coulibaly, P. (2009). Developments in hydrometric network design: A review. *Reviews of Geophysics*, 47(2), 2007RG000243.
<https://doi.org/10.1029/2007RG000243>
- Modest, M. F. (2013). *Radiative heat transfer* (3d edition). Academic Press.
- Montibeller, Á. (2017). *Estimating energy fluxes and evapotranspiration of corn and soybean with an unmanned aircraft system in Ames, Iowa*. University of Northern Iowa.
- Mosavi, A., Ozturk, P., & Chau, K. (2018). Flood Prediction Using Machine Learning Models: Literature Review. *Water* 2018, Vol. 10, Page 1536, 10(11), 1536.
<https://doi.org/10.3390/W10111536>
- Muja, M., & Lowe, D. G. (2009). Fast Approximate Nearest Neighbors with Automatic Algorithm Configuration. *Proceedings of the Fourth International Conference on Computer Vision Theory and Applications (VISIGRAPP 2009) - Volume 1: VISAPP*, 331–340. <https://doi.org/10.5220/0001787803310340>
- Niu, H., Hollenbeck, D., Zhao, T., Wang, D., & Chen, Y. (2020). Evapotranspiration Estimation with Small UAVs in Precision Agriculture. *Sensors*, 20(22), 6427.
<https://doi.org/10.3390/s20226427>

- Novák, V. (2012). *Evapotranspiration in the Soil-Plant-Atmosphere System*. Springer Netherlands. <https://doi.org/10.1007/978-94-007-3840-9>
- Ögütcü, S., & Kalaycı, İ. (2018). Accuracy and precision of network-based RTK techniques as a function of baseline distance and occupation time. *Arabian Journal of Geosciences*, *11*(13), 354. <https://doi.org/10.1007/s12517-018-3712-2>
- Ouédraogo, M. M., Degré, A., Debouche, C., & Lisein, J. (2014). The evaluation of unmanned aerial system-based photogrammetry and terrestrial laser scanning to generate DEMs of agricultural watersheds. *Geomorphology*, *214*, 339–355. <https://doi.org/10.1016/j.geomorph.2014.02.016>
- Pai, H., Malenda, H. F., Briggs, M. A., Singha, K., González-Pinzón, R., Gooseff, M. N., & Tyler, S. W. (2017). Potential for Small Unmanned Aircraft Systems Applications for Identifying Groundwater-Surface Water Exchange in a Meandering River Reach. *Geophysical Research Letters*, *44*(23), 11,868–11,877. <https://doi.org/10.1002/2017GL075836>
- Park, S. (2018). *Estimating plant water stress and evapotranspiration using very-high-resolution (VHR) UAV imagery* [The University of Melbourne]. <http://hdl.handle.net/11343/216508>
- Poblete, T., Ortega-Farías, S., Moreno, M., & Bardeen, M. (2017). Artificial Neural Network to Predict Vine Water Status Spatial Variability Using Multispectral Information Obtained from an Unmanned Aerial Vehicle (UAV). *Sensors*, *17*(11), 2488. <https://doi.org/10.3390/s17112488>
- Priestley, C. H. B., & Taylor, R. J. (1972). On the Assessment of Surface Heat Flux and Evaporation Using Large-Scale Parameters. *Monthly Weather Review*, *100*(2), 81–92. [https://doi.org/10.1175/1520-0493\(1972\)100<0081:OTAOSH>2.3.CO;2](https://doi.org/10.1175/1520-0493(1972)100<0081:OTAOSH>2.3.CO;2)
- Ribeiro-Gomes, K., Hernández-López, D., Ortega, J., Ballesteros, R., Poblete, T., & Moreno, M. (2017). Uncooled Thermal Camera Calibration and Optimization of the Photogrammetry Process for UAV Applications in Agriculture. *Sensors*, *17*(10), 2173. <https://doi.org/10.3390/s17102173>
- Ronneberger, O., Fischer, P., & Brox, T. (2015). *U-Net: Convolutional Networks for Biomedical Image Segmentation*. <https://doi.org/10.48550/ARXIV.1505.04597>
- Schewe, J., Heinke, J., Gerten, D., Haddeland, I., Arnell, N. W., Clark, D. B., Dankers, R., Eisner, S., Fekete, B. M., Colón-González, F. J., Gosling, S. N., Kim, H., Liu, X., Masaki, Y., Portmann, F. T., Satoh, Y., Stacke, T., Tang, Q., Wada, Y., ... Kabat, P. (2014). Multimodel assessment of water scarcity under climate change. *Proceedings of the National Academy of Sciences*, *111*(9), 3245–3250. <https://doi.org/10.1073/pnas.1222460110>
- Sheffield, J., Wood, E. F., Pan, M., Beck, H., Coccia, G., Serrat-Capdevila, A., & Verbist, K. (2018). Satellite Remote Sensing for Water Resources Management: Potential for Supporting Sustainable Development in Data-Poor Regions. *Water Resources Research*, *54*(12), 9724–9758. <https://doi.org/10.1029/2017WR022437>
- Shen, C. (2018). A Transdisciplinary Review of Deep Learning Research and Its Relevance for Water Resources Scientists. *Water Resources Research*, *54*(11), 8558–8593. <https://doi.org/10.1029/2018WR022643>
- Shen, M., Chen, J., Zhuan, M., Chen, H., Xu, C.-Y., & Xiong, L. (2018). Estimating uncertainty and its temporal variation related to global climate models in quantifying

- climate change impacts on hydrology. *Journal of Hydrology*, 556, 10–24.
<https://doi.org/10.1016/j.jhydrol.2017.11.004>
- Shiklomanov, A. I., Lammers, R. B., & Vörösmarty, C. J. (2002). Widespread decline in hydrological monitoring threatens Pan-Arctic Research. *Eos, Transactions American Geophysical Union*, 83(2), 13–17. <https://doi.org/10.1029/2002EO000007>
- Simonyan, K., & Zisserman, A. (2015). *Very Deep Convolutional Networks for Large-Scale Image Recognition* [Software].
- Stöcker, C., Nex, F., Koeva, M., & Gerke, M. (2017). QUALITY ASSESSMENT OF COMBINED IMU/GNSS DATA FOR DIRECT GEOREFERENCING IN THE CONTEXT OF UAV-BASED MAPPING. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLII-2/W6, 355–361. <https://doi.org/10.5194/isprs-archives-XLII-2-W6-355-2017>
- Strahler, A. N. (1957). Quantitative analysis of watershed geomorphology. *Transactions, American Geophysical Union*, 38(6), 913. <https://doi.org/10.1029/tr038i006p00913>
- Su, Z. (2002). The Surface Energy Balance System (SEBS) for estimation of turbulent heat fluxes. *Hydrology and Earth System Sciences*, 6(1), 85–100.
<https://doi.org/10.5194/hess-6-85-2002>
- Szostak, R., Pietroń, M., Wachniew, P., Zimnoch, M., & Cwiąkała, P. (2024). Estimation of Small-Stream Water Surface Elevation Using UAV Photogrammetry and Deep Learning. *Remote Sensing*, 16(8), 1458. <https://doi.org/10.3390/rs16081458>
- Szostak, R., Zimnoch, M., Wachniew, P., & Jasek-Kamińska, A. (2023). Self-Calibration of UAV Thermal Imagery Using Gradient Descent Algorithm. *Drones*, 7(11), 683. <https://doi.org/10.3390/drones7110683>
- Tapiador, F. J., Turk, F. J., Petersen, W., Hou, A. Y., García-Ortega, E., Machado, L. A. T., Angelis, C. F., Salio, P., Kidd, C., Huffman, G. J., & De Castro, M. (2012). Global precipitation measurement: Methods, datasets and applications. *Atmospheric Research*, 104–105, 70–97. <https://doi.org/10.1016/j.atmosres.2011.10.021>
- Tomašík, J., Mokroš, M., Surový, P., Grznárová, A., & Merganič, J. (2019). UAV RTK/PPK Method—An Optimal Solution for Mapping Inaccessible Forested Areas? *Remote Sensing*, 11(6), 721. <https://doi.org/10.3390/rs11060721>
- Trenberth, K. E., Dai, A., Van Der Schrier, G., Jones, P. D., Barichivich, J., Briffa, K. R., & Sheffield, J. (2014). Global warming and changes in drought. *Nature Climate Change*, 4(1), 17–22. <https://doi.org/10.1038/nclimate2067>
- Trenberth, K. E., Fasullo, J. T., & Kiehl, J. (2009). Earth's Global Energy Budget. *Bulletin of the American Meteorological Society*, 90(3), 311–324.
<https://doi.org/10.1175/2008BAMS2634.1>
- UNESCO. (2020). *Water and climate change*.
- UNESCO. (2023). *Partnerships and cooperation for water*.
- Vincent, P., Larochelle, H., Bengio, Y., & Manzagol, P.-A. (2008). Extracting and composing robust features with denoising autoencoders. *Proceedings of the 25th International Conference on Machine Learning - ICML '08*, 1096–1103.
<https://doi.org/10.1145/1390156.1390294>
- Vollmer, M., & Möllmann, K. (2017). *Infrared Thermal Imaging: Fundamentals, Research and Applications* (1. wyd.). Wiley. <https://doi.org/10.1002/9783527693306>

- Voss, M., Deutsch, B., Elmgren, R., Humborg, C., Kuuppo, P., Pastuszak, M., Rolff, C., & Schulte, U. (2006). Source identification of nitrate by means of isotopic tracers in the Baltic Sea catchments. *Biogeosciences*, 3(4), 663–676. <https://doi.org/10.5194/bg-3-663-2006>
- Wan, X. (2019). Influence of feature scaling on convergence of gradient iterative algorithm. *Journal of Physics: Conference Series*, 1213(3), 032021. <https://doi.org/10.1088/1742-6596/1213/3/032021>
- Wohl, E. (2017). The significance of small streams. *Frontiers of Earth Science* 2017 11:3, 11(3), 447–456. <https://doi.org/10.1007/S11707-017-0647-Y>
- Woodget, A. S., Carbonneau, P. E., Visser, F., & Maddock, I. P. (2014). *Quantifying submerged fluvial topography using hyperspatial resolution UAS imagery and structure from motion photogrammetry*. <https://doi.org/10.1002/esp.3613>
- Xia, T., Kustas, W. P., Anderson, M. C., Alfieri, J. G., Gao, F., McKee, L., Prueger, J. H., Geli, H. M. E., Neale, C. M. U., Sanchez, L., Alsina, M. M., & Wang, Z. (2016). Mapping evapotranspiration with high-resolution aircraft imagery over vineyards using one- and two-source modeling schemes. *Hydrology and Earth System Sciences*, 20(4), 1523–1545. <https://doi.org/10.5194/hess-20-1523-2016>
- Yazdandoost, F., Moradian, S., Izadi, A., & Aghakouchak, A. (2021). Evaluation of CMIP6 precipitation simulations across different climatic zones: Uncertainty and model intercomparison. *Atmospheric Research*, 250, 105369. <https://doi.org/10.1016/j.atmosres.2020.105369>
- Yuan, W., & Hua, W. (2022). A Case Study of Vignetting Nonuniformity in UAV-Based Uncooled Thermal Cameras. *Drones*, 6(12), 394. <https://doi.org/10.3390/drones6120394>
- Yuanjie Zheng, Lin, S., Kambhamettu, C., Jingyi Yu, & Sing Bing Kang. (2009). Single-Image Vignetting Correction. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 31(12), 2243–2256. <https://doi.org/10.1109/TPAMI.2008.263>
- Zhao, H., Shi, J., Qi, X., Wang, X., & Jia, J. (2016). *Pyramid Scene Parsing Network*. <https://doi.org/10.48550/ARXIV.1612.01105>
- Żurek, A. J. (2024). *Charakterystyka procesów przepływu, przekształceń jakościowych wody i migracji zanieczyszczeń w strefie aeracji na podstawie badań w lizymetrach*. Wydawnictwa AGH Kraków.