



AGH

AKADEMIA GÓRNICZO-HUTNICZA IM. STANISŁAWA STASZICA W KRAKOWIE

DZIEDZINA NAUK INŻYNIERYJNO-TECHNICZNYCH

DYSCYPLINA INŻYNIERIA LĄDOWA, GEODEZJA I TRANSPORT

ROZPRAWA DOKTORSKA

Monitoring przemieszczeń poziomych z zastosowaniem
uczenia maszynowego do analiz satelitarnych obrazowań
radarowych

Autor: mgr inż. Magdalena Łucka

Promotor rozprawy: Prof. dr hab. inż. Ryszard Hejmanowski
Promotor pomocniczy: Dr inż. Wojciech Witkowski

Praca wykonana: Wydział Geodezji Górniczej i Inżynierii Środowiska
Akademia Górniczo-Hutnicza im. S. Staszica w Krakowie

Kraków, 2025

Pragnę serdecznie podziękować Profesorowi Ryszardowi Hejmanowskiemu oraz Doktorowi Wojciechowi Witkowskiemu za wsparcie i opiekę merytoryczną, a także wszelkie uwagi przy realizacji niniejszej pracy.

Dziękuję również swoim najbliższym, a w szczególności mężowi i rodzicom, za nieustanne wsparcie i cierpliwość okazywane w trakcie realizowanych badań.

Streszczenie

Efektywne monitorowanie wielkopowierzchniowych i dynamicznych ruchów poziomych wciąż pozostaje wyzwaniem. Wśród tego rodzaju ruchów można wyróżnić nagłe osuwiska, przemieszczanie się lodowców, czy też ruchy spowodowane trzęsieniami ziemi. Dostępność takich rejonów jest często ograniczona ze względu na niestabilność gruntu lub położenie w trudnych warunkach terenowych. Często posiadają one znaczące rozmiary powierzchniowe, a okres występowania ruchów bywa nieznany. Wymienione czynniki powodują, że klasyczne techniki geodezyjne są niezwykle trudne do wykorzystania w celu prawidłowego monitoringu. Z uwagi na powyższe ograniczenia, a także intensywny rozwój sektora kosmicznego w ostatnich latach, głównym źródłem danych o dynamicznych ruchach poziomych są obrazy satelitarne, a w szczególności zobrazenia radarowe, pozwalające na pozyskiwanie danych niezależnie od warunków pogodowych czy oświetleniowych.

Istniejące techniki teledetekcyjne do monitorowania ruchów poziomych opierają się głównie na odnajdywaniu odpowiadających sobie obszarów na parze obrazów z wykorzystaniem współczynnika korelacji krzyżowej. Poprawne zaaplikowanie tych metod wymaga wstępnej znajomości obszaru opracowania, gdyż spodziewana skala ruchów ma znaczenie w procesie przetwarzania. W zależności od implementacji w konkretnym oprogramowaniu zmienna jest liczba parametrów, które należy zdefiniować, a ich wartości zmieniają się w zależności od wykorzystywanego sensora satelitarnego czy też badanego obiektu. Z tego względu dobranie optymalnych parametrów przetwarzania może być zadaniem czasochłonnym i wymagającym dogłębnej wiedzy na temat parametrów wykorzystanych danych, oprogramowania, a także obszaru opracowania. Ponadto, pomimo intensywnego rozwoju uczenia maszynowego w wielu dziedzinach, wciąż istnieje niewiele badań skupiających się na próbie analizowania ruchów poziomych z wykorzystaniem sztucznej inteligencji, która mogłaby wesprzeć w tym zakresie analizę zobrażeń radarowych.

W ramach niniejszej pracy głównym celem było stworzenie nowej metody wyznaczania przemieszczeń poziomych w rejonach o dużej dynamice ruchów na podstawie satelitarnych zobrażeń radarowych i uczenia maszynowego. Przeprowadzone badania skupiały się przede wszystkim na analizie użyteczności konwolucyjnych sieci neuronowych do wykrywania tych samych obszarów na obrazach, dla których pomiędzy rejestracją kolejnych danych doszło do przemieszczenia się terenu. Analizy przeprowadzono zarówno na obrazach testowych, które poddano przesunięciu manualnemu o zadany wektor, jak i w warunkach rzeczywistych, aplikując zaproponowaną metodykę do analizy prędkości lodowca. Prócz głównego celu dysertacji przeanalizowano również wpływ poszczególnych parametrów stosowanych w klasycznych metodach teledetekcyjnych na jakość pozyskiwanych map przemieszczeń poziomych. W ramach przeprowadzonych analiz porównywano użyteczność danych z pasma C i X do monitorowania ruchów poziomych, badano wpływ bazy czasowej i rozmiaru okna poszukiwawczego na pozyskiwane wyniki. Dodatkowo wyniki otrzymane w ramach zaproponowanej nowej metody wyznaczania przemieszczeń na podstawie konwolucyjnych sieci neuronowych porównano z wynikami algorytmów już istniejących, co pozwoliło na ocenę dokładności zaproponowanej metodologii. Wyniki przeprowadzonych badań pozwoliły na potwierdzenie postawionej w rozprawie tezy, że zastosowanie algorytmów uczenia maszynowego do analizy satelitarnych zobrażeń radarowych pozwala skutecznie monitorować przemieszczenia poziome lodowców.

Abstract

Effective monitoring of large-scale and dynamic horizontal movements remains a challenge. Such movements include rapid landslides, glacier movements, or movements caused by earthquakes. The accessibility of such regions is often limited due to ground instability or location in difficult terrain. In addition, these areas often have significant area sizes, and the timing of movements is sometimes unknown. The aforementioned factors make classical surveying techniques challenging to use for proper monitoring. Due to the existing limitations, as well as the intensive development of the space sector in recent years, the main sources of data for dynamic horizontal movements monitoring are satellite images, particularly radar images, which allow data acquisition regardless of weather or lighting conditions.

Existing remote sensing techniques for monitoring horizontal movements depend mainly on finding corresponding areas in a pair of images using the cross-correlation coefficient. Correct application of these methods requires preliminary knowledge of the study area, since the expected scale of movements is important in the processing chain. In addition, depending on the implementation in a particular software, the number of parameters to be defined varies, and their values also change depending on the satellite sensor used or the object under study. Therefore, selecting the optimal processing parameters can be a time-consuming task and requires in-depth knowledge of the parameters of the data used, the software, as well as the study area. Moreover, despite the intensive development of machine learning in many fields, there are still a few studies focusing on attempting to analyse horizontal movements using artificial intelligence, which could support radar image analysis.

Within the framework of the present work, the main objective was to create a new method for determining horizontal displacements in regions with high movement dynamics based on machine-learning algorithms and SAR datasets. The research conducted focused primarily on analysing the usefulness of convolutional neural networks for detecting the same areas in images for which terrain displacement occurred between the registration of successive data. Analyses were carried out both on test images, which were subjected to manual displacement by a given vector, and in real conditions, applying the proposed methodology to glacier velocity analysis. In addition to the main objective of the dissertation, the influence of individual parameters used in classical remote sensing methods on the quality of the acquired horizontal displacement maps was also analysed. The analyses carried out compared the usefulness of C-band and X-band data for monitoring horizontal movements and examined the influence of time baseline and registration window size on the acquired results. In addition, the results obtained from the proposed new method of determining displacements based on convolutional neural networks were compared with the results of existing algorithms, which made it possible to assess the accuracy of the proposed methodology. The results of the conducted research made it possible to confirm the thesis set in the dissertation that the application of machine-learning algorithms to the analysis of satellite radar imagery makes it possible to effectively monitor the horizontal displacement of glaciers.

Spis treści

Wykaz skrótów	6
1 Wstęp i aktualny stan wiedzy	7
2 Cele badawcze i teza dysertacji	11
3 Wykaz publikacji będących podstawą rozprawy doktorskiej	12
4 Obszary badawcze i wykorzystane dane	15
5 Metodologia	18
5.1 Opracowanie danych z mikrosatelitów ICEYE	18
5.2 Baza czasowa danych radarowych	19
5.3 Wielkość okna poszukiwawczego w algorytmie OT	20
5.4 Zastosowanie CNN do pomiaru przemieszczeń	21
6 Wyniki i dyskusja	25
6.1 Ocena użyteczności danych ICEYE	25
6.2 Ocena wpływu bazy czasowej	30
6.3 Ocena wpływu rozmiaru okna poszukiwawczego	32
6.4 Zastosowanie CNN do pomiaru przemieszczeń	36
7 Podsumowanie	42
Bibliografia	44
Spis rysunków	48
Spis tabel	49
Załączniki	50

Wykaz skrótów

Adam	Adaptive Moment Estimation
CNN	Convolutional Neural Network
ESA	European Space Agency
GNSS	Global Navigation Satellite Systems
GRD	Ground Range Detected
GrIMP	Greenland Ice Sheet Mapping Project
InSAR	Synthetic Aperture Radar Interferometry
LOS	Line of Sight
MEaSURES	Making Earth System Data Records for Use in Research Environments
ML	Machine Learning
MNiSW	Minister Nauki i Szkolnictwa Wyższego
NASA	National Aeronautics and Space Administration
NCC	Normalised Cross-Correlation
NISAR	NASA-ISRO Synthetic Aperture Radar
NMT	Numeryczny Model Terenu
OT	Offset-Tracking
ReLU	Rectified Linear Unit
S-1	Sentinel-1
SAR	Synthetic Aperture Radar
SGD	Stochastic Gradient Descent
SNAP	SeNtinel Application Platform
SI	Sztuczna Inteligencja
SLC	Single Look Complex
TSX	TerraSAR-X

Rozdział 1

Wstęp i aktualny stan wiedzy

Monitorowanie poziomych przemieszczeń powierzchni terenu stanowi znacznie rzadziej podejmowany problem badawczy niż obserwacja przemieszczeń pionowych. Niemniej ruchy w płaszczyźnie poziomej dotyczą wiele rejonów świata, różniąc się dynamiką ruchu, przyczyną i zasięgiem powierzchniowym. Przemieszczenia te związane są m.in. z ruchami masowymi, tektoniką, efektami działalności górniczej czy też ze spływem lodowców. Szczególnie wymagającymi rejonami są te, które charakteryzują się dużymi wartościami przemieszczeń i znaczącymi prędkościami ruchu. Ruchy poziome stanowią wówczas bezpośrednie zagrożenie dla ludzi, środowiska, zabudowań oraz infrastruktury, a jednocześnie stanowią wyzwanie pod kątem efektywnego sposobu monitorowania. Do tego typu ruchów można zaliczyć gwałtowne osuwiska spowodowane nagłą utratą stabilności zboczy czy też przemieszczanie się lodowców. W przypadku pierwszej grupy ruchów przyczyny mogą być zarówno naturalne, jak i antropogeniczne. Czynniki wpływającymi na występowanie nagłych osuwisk są długotrwałe lub intensywne opady deszczu, topnienie śniegu, podcinanie i obciążanie zboczy przez budowy dróg czy budynków, aktywność wulkaniczna i sejsmiczna, a także wiele innych [1]. W przypadku lodowców główne przyczyny napędzające ruch mas lodowcowych są pochodzenia naturalnego. Są to głównie siła grawitacji oraz naprężenia powstające wskutek nacisku mas lodu na podłoże [2]. Kondycja lodowców ma wpływ zarówno na środowisko lokalne, zaburzając m.in. warunki hydrologiczne, a także na procesy zachodzące globalnie poprzez bezpośredni wpływ na poziom mórz i oceanów. Ponadto znaczące zmiany w prędkości ruchu lodowców skutkują wzrostem naprężeń i w efekcie mogą prowadzić do przzerwiania ciągłości jęzora lodowcowego. Prowadzi to do powstawania szczelin, które następnie odłamują się, tworząc góry lodowcowe lub seraki [3]. Z uwagi na globalne znaczenie kondycji lodowców, szczególnie w dobie zmian klimatycznych, właśnie tym obszarom poświęcono główną uwagę w niniejszej rozprawie doktorskiej.

Lodowce i pokrywy lodowe stanowią obecnie ok. 10-12% powierzchni lądów, z czego 8,3% przypada na lądolód Antarktydy, 1,2% na pokrywę lodową Grenlandii, a 0,5% stanowią lodowce górskie [4]. Duże czapy lodowcowe przemieszczają się z niewielkimi prędkościami lub są stabilne. Lodowce górskie, piedmontowe czy też szelfowe mogą charakteryzować się prędkościami przemieszczeń dochodzącymi nawet do kilkudziesięciu metrów na dobę, szczególnie w okresach tzw. szarży lodowcowej. Znacząca większość lodowców odznacza się jednak prędkościami od kilkudziesięciu do kilkuset metrów rocznie. Prędkość przemieszczania się lodowca zależy od wielu czynników, związanych nie tylko z aktualną pogodą czy klimatem, ale także z morfologią oraz rzeźbą terenu. Monitorowanie przemieszczeń lodowców jest istotne m.in. z perspektywy modelowania całych pokryw lodowych. Informacje o kierunku i zmianach prędkości ruchu pozwalają bowiem na tworzenie bardziej precyzyjnych modeli. Analiza zmian w dynamice spływu lodu dostarcza również informacji pozwalających na lepsze zrozumienie interakcji między atmosferą, hydrologią, oceanami, a samą pokrywą lodową [5]. Zmiany prędkości lodowców wpływają także na tempo cofania się ich czoła. W przypadku lodowców górskich monitorowanie zmian dynamiki pozwala także na

ocenę bezpieczeństwa w danym rejonie oraz oszacowanie kondycji lodowców, będącej odzwierciedleniem zmian klimatycznych zachodzących na Ziemi. Z uwagi na rozległość obszarów, które pokrywają lodowce, a także ograniczoną dostępność, monitorowanie ich przemieszczeń w sposób ciągły w czasie i przestrzeni wciąż pozostaje wyzwaniem.

Tradycyjnie pomiar prędkości lodowca wykonuje się za pomocą tyczek zamontowanych w wybranych częściach lodowca. Najprostszym ze sposobów jest pomiar zmian odległości pomiędzy tyczkami w celu określenia ich względnego przemieszczenia. Wraz z rozwojem technologii GNSS (Global Navigation Satellite Systems) pomiary te zostały jednak wyparte przez zastąpienie tyczek odbiornikami GNSS. Umożliwia to analizę zmiany pozycji punktu pomiarowego w globalnym systemie odniesień przestrzennych, czyli wyznaczenie przemieszczenia bezwzględnego. Dzięki temu możliwe jest przeanalizowanie prędkości spływu lodu w punktach położonych daleko od siebie. Każdy taki pomiar obarczony jest jednak kosztami transportu zespołu pomiarowego do miejsca stabilizacji tyczek. Co więcej, pozyskane wartości przemieszczeń dostarczają tylko punktowych informacji, odpowiadających niewielkiemu zakresowi przestrzennemu. Z tego względu trudne do uchwycenia są anomalie przestrzenne w przepływie lodowców. Z uwagi na ograniczenia czasowo-przestrzenne klasycznych sieci pomiarowych oraz ograniczoną dostępność wielu rejonów świata, największą popularnością obecnie cieszą się metody oparte o teledetekcję z pułapu lotniczego lub satelitarnego [6, 7, 8]. Metody teledetekcyjne z obu pułapów mogą dostarczać danych optycznych, multispektralnych oraz radarowych. Znaczna część obszarów lodowych znajduje się w rejonach na wysokich szerokościach geograficznych, przez co są to obszary występowania m.in. nocy polarnej. Z tego względu, szczególnie dynamicznie rozwijają się metody monitorowania prędkości lodowców na podstawie satelitarnych obrazowań radarowych (ang. Synthetic Aperture Radar — SAR), które dodatkowo dostarczają danych niezależnie od zachmurzenia. Dodatkowym czynnikiem stymulującym rozwój monitorowania lodowców z użyciem danych SAR jest znaczący wzrost liczby satelitów oferujących obrazowania o coraz wyższej rozdzielczości, w różnych pasmach obrazowania i dowolnej bazie czasowej, takich jak ICEYE, Capella, NISAR czy niedawno wyniesiony na orbitę Sentinel-1C (S-1).

Teledetekcyjne metody monitorowania przemieszczeń lodowców można podzielić na dwie główne grupy: interferometrię radarową (ang. SAR Interferometry — InSAR) [9] oraz metody bazujące na podobieństwie obrazów lub poszczególnych cech charakterystycznych zdjęcia i śledzeniu przesunięć między nimi (m.in.: ang. Offset-Tracking — OT, ang. feature tracking, ang. speckle tracking). Pierwsza z tych technik wykorzystuje wyłącznie dane pozyskane z sensorów aktywnych emitujących falę elektromagnetyczną w kierunku powierzchni Ziemi. Obrazowania radarowe posiadają wówczas informację o amplitudzie i fazie sygnału powracającego do sensora. Pojedyncza informacja o wartości fazy nie dostarcza wystarczających danych do wyznaczenia wielkości przemieszczenia. W momencie, gdy dany obszar świata obrazowany jest regularnie pod tym samym kątem patrzenia radaru, możliwe jest jednak wyznaczanie różnicy faz pomiędzy konkretnymi parami obrazów. Posiadając numeryczny model terenu (NMT), możliwe jest określenie zmian występujących na powierzchni terenu przez usunięcie składnika fazy odpowiedzialnego za topografię. Pozostała część fazy wynika w głównej mierze z procesu deformacyjnego zachodzącego w obserwowanym

terenie. Pozyskane w ten sposób wartości informują o przemieszczeniu terenu w kierunku obrazowania satelity, tj. kierunku emitowania wiązki fali elektromagnetycznej przez radar (ang. Line Of Sight — LOS). W celu pozyskania precyzyjnych informacji o ruchu lodowca zarówno w płaszczyźnie pionowej, jak i poziomej, konieczne jest dokonanie dekompozycji pola przemieszczeń. Niezbędne jest do tego posiadanie danych pochodzących z co najmniej dwóch, a najlepiej trzech różnych geometrii obrazowania, co stanowi pierwsze z ograniczeń interferometrii radarowej w zakresie monitorowania kriosfery. Kolejnym z ograniczeń metody InSAR jest wielkość maksymalnego ruchu wykrywalnego przez tę technikę pomiarową. W przypadku ruchów o dużej amplitudzie wyznaczenie całkowitego przemieszczenia LOS w metodzie InSAR bazuje na rozwiązaniu problemu nieoznaczoności fazy, które sprowadza się do określenia ilości pełnych cykli fazy obserwowanych na interferogramie. W przypadku bardzo dużej skali ruchów trudne jest prawidłowe rozwinięcie fazy, a w przypadku niepoprawnego oszacowania ilości cykli wyznaczone przemieszczenie może się okazać niedoszacowane. Ponadto do poprawnego rozwinięcia fazy niezbędna jest dobra jakość i spójność sygnału, odznaczająca się wysokim wskaźnikiem koherencji. W przypadku obszarów pokrytych śniegiem i lodem odbicie może być zakłócone poprzez występowanie świeżych opadów śniegu. Cykliczne zamarzanie i rozmarzanie warstwy przypowierzchniowej lodowca skutkuje zwiększeniem ilości wody na powierzchni, prowadząc do absorpcji sygnału i braku odbicia wiązki radaru. Alternatywną metodą, która pozwala na zniwelowanie części tych problemów, jest technika OT, która nie bazuje na fazie interferometrycznej, lecz wykorzystuje wyłącznie obrazy amplitudy lub obrazy optyczne. Metoda ta polega na podziale obrazów wejściowych na mniejsze kafelki i poszukiwaniu fragmentów, które reprezentują ten sam obszar na zdjęciach pozyskanych w zadanym odstępie czasowym. Poszukiwanie obszarów o podobnej charakterystyce bazuje na wykorzystaniu znormalizowanej korelacji krzyżowej (ang. normalised cross-correlation — NCC) [10, 11]. Wybrany fragment obrazu jest porównywany z kolejnymi próbkami zdjęć pochodzącymi z innej daty. Zdjęcie próbkowane jest w określonym kroku wyrażonym w pikselach i dla każdej próbki wyliczana jest wartość współczynnika NCC. Obszar, dla którego wyliczono najwyższy wskaźnik NCC uznawany jest za pozycję szukanego obiektu na drugim zdjęciu. Na podstawie znanej pozycji obiektu na parze obrazów możliwe jest wyznaczenie przemieszczenia w układzie obrazu, a także późniejsze przeliczenie przesunięć na wartości metryczne wykorzystując informację o rozmiarze terenowym piksela obrazu wejściowego. Technika ta pozwala zatem na wyznaczanie przemieszczeń głównie w płaszczyźnie poziomej, co może być jej ograniczeniem, ale w przypadku monitorowania prędkości przepływu lodowców jest to kluczowa informacja. Zaletami tej techniki pomiarowej jest możliwość uchwycenia wielkoskalowych ruchów powierzchni terenu rzędu setek metrów oraz jej niezależność od koherencji, czyli stabilności sygnału w przypadku sensorów radarowych. Może być ona uzupełnieniem metody InSAR, gdyż jej dokładność ogranicza wielkość piksela terenowego i szacowana jest w literaturze na 1/10-1/30 rozmiaru piksela [12]. Metoda ta jednak w dużej mierze zależy od rozdzielczości danych wejściowych i zwykle wymaga dobrej znajomości badanego rejonu, gdyż wielkość spodziewanych ruchów w dużej mierze wpływa na parametryzację procesu przetwarzania.

Ograniczenia istniejących metod oraz rozwój takich dziedzin jak rozpoznawanie obrazów (ang. computer vision) i sztuczna inteligencja (SI) doprowadziły do rosnącej liczby modeli uczenia maszynowego (ang.

machine learning — ML) do analizy danych satelitarnych. Pomimo tego, wciąż istnieje niewiele rozwiązań wykorzystujących fuzję danych SAR i modeli ML do analizy przemieszczeń powierzchni terenu. Wśród istniejących badań w tym zakresie znaczącą grupę stanowią prace poświęcone predykcji przemieszczeń powierzchni terenu [13, 14, 15] oraz detekcji obszarów niestabilnych [16, 17, 18, 19]. Szczególnie wąską grupę stanowią prace wykorzystujące techniki SI do wyznaczania samych wartości przemieszczeń, co mogłoby wspomóc automatyzację procesu pozyskiwania danych o prędkościach lodowców, niezależnie od typu obrazów wejściowych. Jednym z alternatywnych podejść do wyznaczania prędkości, bazującym na rozwiązaniach widzenia komputerowego, jest algorytm przepływu optycznego (ang. Optical Flow). Metoda ta zakłada, że intensywność pikseli pomiędzy dwoma kolejnymi klatkami filmu czy też zdjęciami jest niezmienna, a piksele znajdujące się w bliskim sąsiedztwie poruszają się z tą samą prędkością. Koncepcja przepływu optycznego najczęściej jednak znajdowała zastosowania w analizie obrazów optycznych, wykorzystując ortofotomapy, zdjęcia z kamer naziemnych czy też zdjęcia satelitarne [20, 21, 22]. Wciąż istnieją jedynie pojedyncze testy wykorzystujące przepływ optyczny do monitorowania przemieszczeń na bazie danych SAR. Innym podejściem do wyznaczenia przemieszczeń poziomych z wykorzystaniem SI jest zastosowanie sieci neuronowych, w szczególności sieci bliźniaczych (ang. Siamese Neural Networks) [23]. Główną ideą tego podejścia jest wykorzystanie dwóch pracujących równolegle sieci neuronowych o tej samej architekturze i współdzielonych wagach, które pracują na dwóch różnych danych wejściowych. W ramach kolejnych warstw konwolucyjnych dokonywana jest ekstrakcja cech charakterystycznych każdego z obrazów. W warstwie wyjściowej modelu otrzymywana jest informacja o stopniu podobieństwa danych wejściowych, co pozwala na identyfikację odpowiadających sobie obszarów. Inne podejście do wyznaczania przemieszczeń poziomych, które również korzysta z sieci bliźniaczych, zostało zaproponowane przez Kim i in. [24]. Badacze w swoim podejściu zaproponowali zintegrowanie sieci syjamskich z architekturą U-Net. Zaprojektowany w ten sposób model wykorzystuje jako zbiór treningowy nie tylko surowe obrazy radarowe, ale także wstępnie obliczone pole przemieszczeń poziomych. Takie rozwiązanie wymaga jednak budowy znaczącego zbioru treningowego oraz wstępnego przetwarzania danych technikami teledetekcyjnymi, co nie jest wymagane w przypadku wcześniej omówionych koncepcji. Przytoczone prace, badające wykorzystanie technik SI do monitorowania ruchów poziomych, często koncentrują się na pojedynczych studiach przypadku lub na wykorzystaniu obrazów optycznych. Nieliczne prace skupiają się na wykorzystaniu wyłącznie obrazów SAR i uczenia maszynowego do tego celu. Niemniej jednak prace te wskazują, że istnieje potencjał w wykorzystaniu uczenia maszynowego do efektywnego wyznaczania pola przemieszczeń na bazie danych satelitarnych, który wciąż nie został dogłębnie zbadany.

Przeprowadzone badania literaturowe wykazują, że pomimo znacznego zainteresowania monitorowaniem obszarów glacialnych oraz danymi satelitarnymi, wciąż nie są dobrze zbadane możliwości integracji modeli uczenia maszynowego z danymi SAR do monitorowania ruchów poziomych lodowców. W niniejszej pracy przeprowadzono analizę istniejących metod monitorowania lodowców pod kątem optymalnego doboru parametrów wejściowych i ich wpływu na jakość pozyskiwanych wyników. Ponadto wykorzystano narzędzia uczenia maszynowego, w szczególności konwolucyjne sieci neuronowe, do stworzenia niezależnej metody wyznaczania pola przemieszczeń poziomych na bazie współrejestrowanych obrazów radarowych.

Rozdział 2

Cele badawcze i teza dysertacji

Głównym celem niniejszej rozprawy doktorskiej jest opracowanie nowej metody wyznaczania przemieszczeń poziomych w rejonach o dużej dynamice ruchów na podstawie satelitarnych zobrazowań radarowych oraz z wykorzystaniem uczenia maszynowego. Metoda ta pozwala na wyznaczanie wartości przemieszczeń, ograniczając dodatkową, złożoną parametryzację procesu przetwarzania.

W ramach przeprowadzonych prac badawczych wyodrębniono również następujące cele szczegółowe:

- ocena możliwości wykorzystania danych SAR pochodzących z mikrosatelitów do monitorowania prędkości lodowców,
- ocena wpływu bazy czasowej obrazów radarowych na pozyskiwanie wartości przemieszczeń poziomych,
- wyznaczenie optymalnych rozmiarów okna poszukiwawczego stosowanego w metodzie OT,
- opracowanie modelu uczenia maszynowego pozwalającego na detekcję tożsamyh rejonów na parze obrazów wejściowych,
- porównanie efektywności klasycznych metod teledetekcyjnych oraz rozwiązania opartego o uczenie maszynowe do wyznaczania przemieszczeń poziomych.

Biorąc pod uwagę obecny stan wiedzy, postawiono następującą tezę: **„Zastosowanie algorytmów uczenia maszynowego do analiz satelitarnych zobrazowań radarowych pozwala skutecznie monitorować przemieszczenia poziome lodowców”**.

Rozdział 3

Wykaz publikacji będących podstawą rozprawy doktorskiej

Przygotowana rozprawa doktorska składa się z cyklu 4 spójnych tematycznie artykułów naukowych. Badania zostały opublikowane w czasopismach znajdujących się w wykazie czasopism naukowych i recenzowanych materiałów z konferencji naukowych, przygotowywanym i aktualizowanym przez Ministra Nauki (dawn. Ministra Nauki i Szkolnictwa Wyższego), nazywanego dalej wykazem MNiSW. Poniżej opisano wszystkie prace wchodzące w skład cyklu publikacji wraz ze wskaźnikami czasopism na dzień publikacji artykułu:

1. Łukosz M., Hejmanowski R., Witkowski W. (2021) *Evaluation of ICEYE microsatellites sensor for surface motion detection — Jakobshavn glacier case study*, *Energies*, vol. 14 iss. 12 art. no. 3424, pp. 1–13, DOI: 10.3390/en14123424
Data publikacji: 10.06.2021 r.
Punktacja wg. wykazu MNiSW: 140 pkt.
Impact Factor (IF): 3.2
Udział procentowy: Łukosz M. - 50%, Hejmanowski R. - 20%, Witkowski W. - 30%.
2. Łukosz M., Hejmanowski R., Witkowski W. (2022) *Analysis of the velocity changes of the Jakobshavn Glacier based on SAR imagery*, *Quaestiones Geographicae*, vol. 41 iss. 1, s. 93–105. DOI: 10.2478/quageo-2022-0007
Data publikacji: 19.03.2022 r.
Punktacja wg. wykazu MNiSW: 100 pkt.
Impact Factor (IF): -
Udział procentowy: Łukosz M. - 70%, Hejmanowski R. - 10%, Witkowski W. - 20%.
3. Łucka M., Hejmanowski R., Witkowski W. (2023) *Temporal development of the displacement field of the Ponzano landslide in February 2017*, *Bulletin of Geography. Socio-Economic Series*, no. 62, s. 137–151, DOI: 10.12775/bgss-2023-0039
Data publikacji: 30.12.2023 r.
Punktacja wg. wykazu MNiSW: 140 pkt.
Impact Factor (IF): 0.7
Udział procentowy: Łucka M. - 60%, Hejmanowski R. - 15%, Witkowski W. - 25%.
4. Łucka M. (2025) *Investigation of machine learning algorithms to determine glaciers displacements*, *Remote Sensing Applications: Society and Environment*, vol. 37, no. 101476
Data publikacji: 31.01.2025 r.
Punktacja wg. wykazu MNiSW: 100 pkt.
Impact Factor (IF): 3.8
Udział procentowy: Łucka M. - 100%.

Pierwszy z artykułów [25] skupia się na walidacji zobrazowań pochodzących z satelitów ICEYE do monitorowania ruchu lodowców na przykładzie grenlandzkiego lodowca Jakobshavn. W artykule skupiono się na porównaniu użyteczności satelitarnych zobrazowań radarowych z satelitów obrazujących w paśmie X (ICEYE) oraz w paśmie C (S-1). Otrzymane mapy prędkości porównano w sposób ilościowy i jakościowy, aby sprawdzić możliwości wykorzystania pasma X i nowego sensora SAR do wiarygodnego wyznaczania przemieszczeń poziomych w rejonach lodowcowych.

W drugim z artykułów [26] przeanalizowano jakość map prędkościowych dla wybranego lodowca w zależności od pory roku (zima/lato) oraz długości bazy czasowej pomiędzy kolejnymi zobrazowaniami. W analizach odnoszących się do bazy czasowej badano efektywność metody OT dla okresów sześciodniowego i miesięcznego. Wyznaczone prędkości przemieszczeń dla różnych baz czasowych i pór roku porównano z prędkościami lodowca pochodzącymi z niezależnej bazy danych GrIMP (Greenland Ice Sheet Mapping Project). Porównanie to miało na celu ocenę wiarygodności wyników otrzymanych metodą OT dla różnych danych wejściowych. Ponadto dla wyników z dwóch różnych pór roku możliwa była ocena wpływu warunków atmosferycznych na jakość map, przy założeniu mniejszego topnienia warstwy przypowierzchniowej w zimie.

Trzecia publikacja [27] została poświęcona analizie wielkości przemieszczeń poziomych na terenie nagłego osuwiska. Zaproponowany w tym artykule obszar badawczy nie jest zlokalizowany w rejonach polarnych, czym odstaje od pozostałych artykułów. Obserwowana w tym obszarze skala ruchów oraz ich główny kierunek są jednak zbliżone do tych rejestrowanych dla lodowców. Z tego względu możliwe było zaaplikowanie takich samych metod teledetekcyjnych do monitorowania ruchów poziomych, co w pozostałych artykułach. Prace na tym obszarze badawczym pozwoliły na uzupełnienie analiz dotyczących efektywności metody OT w rejonach o znacznie mniejszym zakresie powierzchniowym ruchów poziomych. W tym artykule skupiono się na porównaniu wysokorozdzielczych obrazów satelity TerraSAR-X (TSX) oraz obrazów o średniej rozdzielczości, pochodzących z misji S-1. Dzięki temu możliwa była ocena wpływu rozdzielczości zobrazowań radarowych na możliwości wykrywania ruchów poziomych o stosunkowo niewielkim zakresie powierzchniowym. W ramach przeprowadzonych prac przeanalizowano różne rozmiary okien poszukiwawczych i ich wpływ na jakość oraz wiarygodność map przemieszczeń. Dzięki analizie wyników w obszarach stabilnych możliwe było określenie wewnętrznej dokładności metody OT na podstawie analizy odchyłeń standardowych.

Ostatni artykuł wchodzący w skład cyklu [28] skupia się na stworzeniu alternatywnej metody służącej do pomiaru przemieszczeń poziomych na bazie obrazów SAR. Podejście zaproponowane w pracy opiera się o algorytmy uczenia maszynowego. Ideą nowej metody jest odnalezienie tożsamyh obszarów na dwóch zdjęciach z użyciem konwolucyjnych sieci neuronowych (ang. convolutional neural network — CNN). Jako dane wejściowe do modelu służą współrejestrowane pary obrazów radarowych. Wyznaczenie najbardziej zbliżonych do siebie fragmentów obrazów traktowane jest jako problem klasyfikacyjny, a przeliczenie na wartości metryczne przemieszczeń odbywa się na podstawie współrzędnych środków

zdjęć i wielkości piksela terenowego danych wejściowych. W artykule zajęto się również problemem poszerzania zbioru treningowego za pomocą modyfikacji oryginalnych fragmentów zdjęć, w taki sposób, aby symulować możliwy zakres ruchu lodowca. W celu wiarygodnej oceny użyteczności i dokładności zaproponowanego podejścia badania przeprowadzono zarówno na zestawach danych syntetycznych, jak i na danych rzeczywistych. Zaproponowano także metodykę filtrowania pozyskiwanych wyników w celu redukcji szumów oraz danych obarczonych dużą niepewnością. Ostateczne wartości przemieszczeń dla jednego z lodowców grenlandzkich (Daugaard-Jensen) zostały porównane z wynikami klasycznego podejścia teledetekcyjnego wykorzystującego metodę OT. Skrypty powstałe w wyniku prac nad artykułem znajdują się w załączniku do niniejszej rozprawy oraz są dostępne w ramach repozytorium na platformie GitHub pod adresem: <https://github.com/magdalucka/TrackOff>.

Pierwsze trzy artykuły w sposób szczegółowy analizują już istniejące metody teledetekcyjne służące do pomiaru przemieszczeń poziomych w różnych warunkach terenowych. Badania skupiały się na ocenie wpływu jakości danych wejściowych oraz wartości parametrów przetwarzania w metodzie OT na jakość i wiarygodność pozyskiwanych wyników. Jest to część poświęcona analizie mocnych i słabych stron istniejących algorytmów oraz stanowi próbę zrozumienia mnogości czynników zarówno technicznych, jak i terenowych, które wpływają na możliwość detekcji szybkich ruchów poziomych. **Ostatni z artykułów skupia się na zaproponowaniu alternatywnej, nowej metody przetwarzania danych SAR z wykorzystaniem sieci neuronowych i jest zasadniczą częścią rozprawy doktorskiej odpowiadającą na postawioną tezę badawczą.**

Rozdział 4

Obszary badawcze i wykorzystane dane

Badania w ramach realizowanej rozprawy doktorskiej realizowane były dla trzech różnych obszarów (Rys. 4.1). W artykule nr 1 [25] oraz nr 2 [26] skupiono się na analizie lodowca Jakobshavn na zachodnim wybrzeżu Grenlandii. W artykule nr 3 [27] skupiono się na osuwisku w Ponzano we Włoszech. W ostatnim z artykułów składających się na cykl publikacji analizowano prędkości dla lodowca Dagaard-Jensen zlokalizowanego na wschodnim wybrzeżu Grenlandii [28].

Lodowiec Jakobshavn


Lodowiec Jakobshavn zlokalizowany jest w centralnej części zachodniego wybrzeża Grenlandii i uchodzi do zatoki Ilulissat. Jest to jeden z najszybszych lodowców na świecie, który swoje maksimum prędkości osiągnął w roku 2012 r., gdy średnia prędkość dobową sięgnęła 46 m/dzień [29, 30]. Lodowiec ten jest największy na Grenlandii i obejmuje zasięgiem ponad 110 000 km² odpowiadając za niemal 7% odpływu grenlandzkiego lodu do oceanu. Ponadto produkuje ok. 10% wszystkich gór lodowych w rejonie Grenlandii. W 2016 r. lodowiec zaczął przybierać na masie, lecz wciąż pozostaje jednym z najszybciej poruszających się na świecie [31]. Jakobshavn mierzy ok. 65 km długości, a średnia grubość wynosi około 2000 m.

Osuwisko Ponzano

Ponzano zlokalizowane jest we centralno-wschodniej części Włoch w regionie Abruzzo i prowincji Teramo. Jest to górzysty obszar z dużym zagrożeniem osuwiskowym. Przedmiotem badań było osuwisko o powierzchni 57 ha, które uległo gwałtownej reaktywacji 12 stycznia 2017 r. na skutek ulewnych deszczy oraz topnienia śniegu. Średnie nachylenie w tym rejonie wynosi 11°. Obszar pokryty jest głównie trawami i uprawami z niewielką ilością dróg i domów, które zostały częściowo uszkodzone w 2017 r. W rejonie tym prowadzono obserwacje metodą interferometrii radarowej (InSAR) przed wystąpieniem osuwiska, gdzie zanotowano przemieszczenie rzędu 10-40 cm na przestrzeni 14 lat [32]. Po wystąpieniu osuwiska przez kilka miesięcy prowadzono również w rejonie monitoring z wykorzystaniem tachimetrów zrobotyzowanych oraz odbiorników GNSS, które wykazały przemieszczenia dochodzące do 75 cm w czasie 5 miesięcy po reaktywacji osuwiska [33].

Lodowiec Dagaard-Jensen

Dagaard-Jensen znajduje się we wschodniej części Grenlandii i spływa do zatoki Nordvestfjord. Zajmuje powierzchnię ok. 50150 km² i jest najszerszym lodowcem na Grenlandii uchodzącym do morza. Dagaard-Jensen odpowiada za odwodnienie ok. 4% całego lądolodu grenlandzkiego. Średnia prędkość tego lodowca dochodzi do ok. 9-10 m/dzień.



Rysunek 4.1: Lokalizacja obszarów badawczych: (A) lodowce grenlandzkie i (B) osuwisko Ponzano na podkładzie satelitarnym.

Wykorzystane dane

W ramach wykonanych analiz bazowano na danych radarowych z trzech różnych sensorów: S-1, ICEYE oraz TSX. W niniejszej sekcji zaprezentowano wykaz wszystkich wykorzystanych zobrazowań w Tab. 4.1. Podczas analizowania wpływu bazy czasowej oraz użyteczności danych z pasma X dokonano analiz porównawczych z mapami prędkościowymi udostępnionymi w ramach projektu Greenland Ice Mapping Project (GrIMP). Dane te publikowane są w ramach inicjatywy NASA (National Aeronautics and Space Administration) o nazwie Making Earth System Data Records for Use in Research Environments (ME-aSUREs), mającej na celu zapewnienie otwartego dostępu do danych na potrzeby prowadzenia badań naukowych. W ramach upublicznionej bazy danych dostępne są między innymi mapy prędkości lodowców dla całej Grenlandii wraz z błędami ich wyznaczenia. Dane publikowane są dla różnych interwałów czasowych: 6/12-dniowych, miesięcznych, kwartalnych czy rocznych. Na potrzeby analiz wykorzystano produkty w formacie GeoTIFF dla 6-dniowych [34] i miesięcznych baz czasowych [35]. Rozdzielczość przestrzenna rastrów wynosi 200×200 m. Źródłem danych dla map krótkoterminowych są zobrazowania SAR pochodzące z satelitów misji S-1. Dla mozaik miesięcznych źródłem danych są zarówno satelity S-1, jak i obrazy z sensora TSX czy też satelitów optycznych Landsat-8 i 9.

Tabela 4.1: Wykaz wykorzystanych zobrażeń radarowych.

Obszar	L.p.	Data	Sensor	Pasmo	Orbita	Polaryzacja	Produkt	Rozdzielczość	Nr art.
Jakobshavn	1	31/01/2017	S-1	C	desc	HH	GRD	10 × 10 m	2
	2	06/02/2017	S-1	C	desc	HH	GRD	10 × 10 m	2
	3	24/02/2017	S-1	C	desc	HH	GRD	10 × 10 m	2
	4	30/07/2017	S-1	C	desc	HH	GRD	10 × 10 m	2
	5	05/08/2017	S-1	C	desc	HH	GRD	10 × 10 m	2
	6	29/08/2017	S-1	C	desc	HH	GRD	10 × 10 m	2
	7	03/01/2021	S-1	C	desc	HH	GRD	10 × 10 m	1,2
	8	09/01/2021	S-1	C	desc	HH	GRD	10 × 10 m	1,2
	9	01/08/2021	S-1	C	desc	HH	GRD	10 × 10 m	2
	10	07/08/2021	S-1	C	desc	HH	GRD	10 × 10 m	2
	11	05/01/2021	ICEYE	X	desc	VV	GRD	2,5 × 2,5 m	1
	12	09/01/2021	ICEYE	X	desc	VV	GRD	2,5 × 2,5 m	1
Ponzano	13	06/02/2017	S-1	C	asc	VH	SLC	2,33 × 13,92 m	3
	14	18/02/2017	S-1	C	asc	VH	SLC	2,33 × 13,92 m	3
	15	10/02/2017	TSX	X	asc	HH	SSC	1,36 × 2,19 m	3
	16	21/02/2017	TSX	X	asc	HH	SSC	1,36 × 2,19 m	3
	17	05/03/2017	TSX	X	asc	HH	SSC	1,36 × 2,19 m	3
Daugaard-Jensen	18	03/02/2024	S-1	C	desc	HH	GRD	10 × 10 m	4
	19	15/02/2024	S-1	C	desc	HH	GRD	10 × 10 m	4
	20	27/02/2024	S-1	C	desc	HH	GRD	10 × 10 m	4
	21	10/03/2024	S-1	C	desc	HH	GRD	10 × 10 m	4

Rozdział 5

Metodologia

Praca skupia się na problemie monitorowania wielkoskalowych poziomych przemieszczeń powierzchni terenu z wykorzystaniem danych satelitarnych. W przeprowadzonych badaniach przeanalizowano istniejące algorytmy do wyznaczania tego rodzaju ruchów oraz wpływ poszczególnych parametrów na jakość uzyskiwanych wyników. Ponadto zaproponowano alternatywne podejście w oparciu o model uczenia maszynowego. W rozdziałach od 5.1 do 5.3 omówiono kolejny wpływ takich czynników jak: rozdzielczość danych radarowych, baza czasowa i rozmiar okna poszukiwawczego. W ostatniej sekcji (Rozdz. 5.4) omówiono zaproponowaną nową metodykę wyznaczania przemieszczeń poziomych.


5.1 Opracowanie danych z mikrosatelitów ICEYE

Badania możliwości wykorzystania zobrażeń z satelitów ICEYE wykonano na przykładzie lodowca Jakobshavn. W tym celu wykorzystano dwa zobrażenia ICEYE oraz dwa obrazy S-1 pozyskane w podobnym czasie do wyznaczenia przemieszczeń poziomych metodą OT. Dla danych ICEYE baza czasowa wyniosła 4 dni, a w przypadku danych S-1 6 dni. Parametry techniczne zobrażeń przedstawiono w Tab. 4.1. Przetwarzanie danych wykonano w otwartym oprogramowaniu SeNtinel Application Platform (SNAP) udostępnianym przez Europejską Agencję Kosmiczną (ESA). Wstępne przygotowanie danych różniło się dla obu zestawów danych. W przypadku danych S-1 w pierwszym kroku dokonano korekcji położenia obrazów poprzez dołączenie informacji o orbitach precyzyjnych satelity oraz przycięto obszar opracowania do rejonu samego lodowca Jakobshavn. Dla danych ICEYE nie posiadano informacji o orbitach precyzyjnych, natomiast niezbędne było wykonanie dodatkowej filtracji obrazów w celu usunięcia efektu tzw. soli i pieprzu (ang. speckle effect). Następne kroki przetwarzania były tożsame dla obu sensorów. Osobno dla danych ICEYE i S-1 dokonano współrejestracji zobrażeń w oparciu o NMT pochodzący z programu Copernicus o rozdzielczości przestrzennej wynoszącej 30 m [36]. Na tak przygotowanych parach zobrażeń wykonano obliczenia metodą OT. Parametry przetwarzania dla obu sensorów były jednakowe i przedstawiono je w Tab. 5.1. W celu zapewnienia podobnej gęstości punktów wynikowych ustawiono wielkość siatki obliczeniowej na 40 pikseli i 10 pikseli kolejno dla danych ICEYE i S-1. Różnica ta jest spowodowana 4-krotnie mniejszym pikselem terenowym dla produktów z pasma X.

Tabela 5.1: Parametry wykorzystane do obliczeń metodą OT w artykule nr 1.

Parametr	ICEYE	Sentinel-1
Max. prędkość [m/dzień]	50	50
Wysokość okna poszukiwawczego [piksele]	128	128
Szerokość okna poszukiwawczego [piksele]	128	128
Odstęp w siatce punktów dla kierunku azymutalnego	40	10
Odstęp w siatce punktów dla kierunku zasięgu	40	10

W wyniku obliczeń otrzymano mapy przemieszczeń poziomych dla obu sensorów dla kierunku azymutalnego, kierunku zasięgu radaru, a także maksymalne prędkości. Ocenę użyteczności danych ICEYE oceniono poprzez bezpośrednie porównanie wartości z danymi S-1 oraz z mapami prędkości z bazy GrIMP. Porównanie danych ICEYE z S-1 wykonano w czterech obszarach o różnej dynamice ruchów, dla których próbkowano rastry z przemieszczeniami w gęstej siatce punktów. Obszar 1 zlokalizowany jest w rejonie niewielkich prędkości lodowca i wchodzi w głąb lądu, obszar 2 zlokalizowany jest w rejonie umiarkowanych prędkości, obszar 3 w rejonie zintensyfikowanych ruchów oraz obszar 4 zlokalizowany przy samym czole lodowca. Następnie w każdym z rejonów wyznaczono współczynnik determinacji (R^2), świadczący o stopniu podobieństwa pomiędzy dwoma sensorami. Dodatkowo przeanalizowano różnicę między sensorami wzdłuż profilu poprowadzonego w osi lodowca. Dokładne położenie analizowanych obszarów i przebieg profilu znajdują się w Załączniku 1 (Rys. 1). Porównanie z niezależną bazą danych wykonano dla całego obszaru lodowca, łącznie z relatywnie stabilnym otoczeniem głównego jezora lodowcowego. Dla całego rejonu wygenerowano siatkę punktów i w niej próbkowano rastry z maksymalnymi prędkościami pochodzącymi z danych ICEYE, S-1 oraz z bazy GrIMP. Pomiedzy otrzymanymi wartościami wyznaczono współczynniki korelacji, aby ocenić spójność otrzymanych wyników. Na Rys. 5.1 schematycznie przedstawiono proces przetwarzania oraz analizy pozyskanych danych.



Rysunek 5.1: Schemat przetwarzania i analizy danych na potrzeby oceny użyteczności danych ICEYE.

5.2 Baza czasowa danych radarowych

Wpływ bazy czasowej na wyznaczone wartości poziome badano na lodowcu Jakobshavn za pomocą danych S-1 (Tab. 4.1). W tym celu wykonano obliczenia metodą OT dla miesiąca zimowego i letniego 2017 r. zarówno dla 6-dniowej bazy czasowej, jak i dla 24- lub 30-dniowego odstępu czasowego. Przetwarzanie danych wykonano w oprogramowaniu SNAP i podjęto kroki analogiczne jak w Rozdz. 5.1. Do pobranych obrazów SAR dołączono informacje o orbitach precyzyjnych oraz przycięto obszar opracowania do rejonu lodowca. W następnym kroku każdą parę zdjęć poddano współrejestracji w oparciu o NMT ACE30. Dla każdej pary obrazów, niezależnie od bazy czasowej, dokonano obliczeń metodą OT z parametrami jak w Tab. 5.2.

Tabela 5.2: Parametry wykorzystane do obliczeń metodą OT w artykule nr 2.

Parametry	
NMT	ACE30
Rozmiar siatki punktów	20 × 20 pxl (200 × 200 m)
Wielkość okna poszukiwawczego	128 × 128 pikseli
Max. prędkość	40 m/dzień

W celu oceny wpływu bazy czasowej na pozyskiwane wyniki, otrzymane mapy dla obu pór roku i obu baz czasowych poddano wizualnej ocenie. Szczególną uwagę zwrócono na ilość szumów w otoczeniu lodowca, a także linearność otrzymywanych wartości. Wyznaczone prędkości odniesiono do wielkości z bazy danych GrIMP dla analogicznego okresu. Dla całego obszaru lodowca wygenerowano siatkę punktów, którym przypisano prędkości pochodzące zarówno z danych S-1 w obu bazach czasowych, jak i wartości z bazy GrIMP. Następnie dla krótkiej bazy czasowej i długiej wykonano wykresy korelacji. Ocenę jakości wyników przeprowadzono w oparciu o wyznaczone współczynniki determinacji.

5.3 Wielkość okna poszukiwawczego w algorytmie OT


Analizy dotyczące wpływu rozmiaru okna poszukiwawczego na jakość wyników w metodzie OT przeprowadzono na osuwisku w Ponzano, wykorzystując dane zarówno S-1, jak i TSX (Tab. 4.1). W przypadku sensora S-1 obliczenia wykonano wyłącznie dla fazy najbardziej dynamicznych ruchów osuwiska dla 12-dniowej bazy czasowej. Dane z TSX przetworzono w trzech kombinacjach (1) dla 11-dniowej bazy czasowej w głównej fazie ruchów, (2) dla 11-dniowej bazy czasowej w okresie tuż po reaktywacji osuwiska oraz (3) dla 22-dniowej bazy czasowej obejmującej okresy (1) i (2) łącznie. Obliczenia wykonano w oprogramowaniu Gamma. Wszystkie pary zobrazowań zostały poddane współrejestracji w oparciu o NMT Copernicus o rozdzielczości 30 m. Obliczenia metodą OT w tym przypadku zostały wykonane iteracyjnie w celu zwiększenia dokładności wyznaczonych przemieszczeń poziomych. W pierwszej iteracji oszacowane są wstępne przesunięcia między dwoma zdjęciami, natomiast w drugiej iteracji dokonywane jest precyzyjne dopasowanie zdjęć w celu poprawienia jakości wyników. Wynikowe mapy przemieszczeń na obu kierunkach zobrazowań SAR zostały dodatkowo przefiltrowane za pomocą maski NCC o wartości progowej równej 0,2.

W ramach analizy okien poszukiwawczych skupiono się na jednym okresie obliczeniowym dla danych TSX o 11-dniowej bazie czasowej, gdzie nastąpiły główne ruchy osuwiska Ponzano. Mapy przemieszczeń poziomych w kierunkach azymutalnych oraz na kierunku zasięgu radaru zostały przeanalizowane oddzielnie dla wielu kombinacji okien poszukiwawczych. Przetestowano następujące wielkości okien poszukiwawczych: 16 × 16, 32 × 16, 64 × 32, 64 × 64, 128 × 64, 128 × 128, 256 × 128 oraz 256 × 256 pikseli. Wybrane kombinacje polegają na 2-krotnym zwiększaniu okna poszukiwawczego w jednym lub obu kierunkach. Przetestowano zarówno kwadratowe, jak i prostokątne okna poszukiwawcze, z uwagi na to, że dla kierunku azymutalnego (*azimuth*) rozdzielczość przestrzenna spada w stosunku do kierunku zasięgu radaru (*range*). Założono brak przemieszczeń w obu kierunkach poza granicami osuwiska. W celu oceny optymalnej wielkości okna poszukiwawczego założono wokół obszaru osuwiska dwa bufory o wielkości 200 m oraz 1000 m wokół granic, wykluczając jednocześnie obszar samych ruchów osuwiska. W następnym kroku w bufo-

rach policzono średnią wartość ruchów na kierunkach azymutalnych oraz zasięgu i obliczono odchylenia standardowe dla obu wartości w zdefiniowanych buforach. Zgodnie z założeniami, zarówno średnia, jak i odchylenie standardowe bliskie zerowemu przemieszczeniu wskazują na lepszą jakość map przemieszczeń.

5.4 Zastosowanie CNN do pomiaru przemieszczeń

W celu opracowania alternatywnej metody wyznaczania przemieszczeń poziomych, bazującej na zobrażeniach SAR i uczeniu maszynowym, konieczne było dodatkowe przygotowanie danych wejściowych, a następnie przetestowanie różnych architektur CNN oraz parametrów uczenia. Główną ideą zastosowania uczenia maszynowego dla wspomnianego celu jest poszukiwanie odpowiadających sobie fragmentów dwóch obrazów ze wsparciem SI. Z uwagi na to, że ideą problemu jest rozpoznanie obrazów o jak najbardziej podobnych wzorach, budowę modelu skupiono tylko i wyłącznie na CNN, które zgodnie z istniejącą literaturą są najbardziej efektywnym narzędziem do pracy z obrazami [37, 38, 39]. Zastosowana metodologia i kolejne etapy pracy zostały schematycznie przedstawione na Rys. 5.2 oraz omówione w kolejnych sekcjach niniejszego rozdziału. Końcowym etapem analiz było opracowanie prawidłowej ścieżki maskowania i filtracji otrzymanych danych oraz walidacji metody w oparciu o niezależne obliczenia, w celu prawidłowej oceny jakości pozyskanych wyników.



Rysunek 5.2: Schemat postępowania w celu wyznaczenia przemieszczeń poziomych z wykorzystaniem modelu ML.

Przygotowanie danych wejściowych

Produktem początkowym do budowania zbioru treningowego są obrazy amplitudy zobrażeń radarowych, które poddano współrejestracji na podstawie NMT. W kolejnym etapie na pierwszym z obrazów wyznaczana jest siatka punktów definiująca gęstość pozyskiwanych informacji, a także definiowany jest promień poszukiwawczy, który pozwala zawęzić obszar poszukiwań. Współrzędne punktów nanoszone są na zdjęcie dopasowywane, a następnie wykonywane jest próbkowanie obrazu w zakresie określonego promienia poszukiwawczego z krokiem co 1 piksel. Każda z pozyskanych w ten sposób próbek o rozmiarze 100×100 pikseli symbolizuje niezależną klasę, która będzie brała udział w procesie uczenia CNN. W celu zwiększenia ilości próbek uczących pozyskane fragmenty obrazu były poddawane takim procesom jak zmiana rozmiaru zdjęcia, filtracja czy też obrót. Prócz zwiększania liczby próbek, dodatkowe przetwarzanie

obrazów ma na celu uodpornienie modelu na zmiany mogące zachodzić w realnych warunkach, takich jak rozciąganie warstwy przypowierzchniowej lodowca czy też zmiana kierunku spływu.

Testowanie modeli uczenia maszynowego

Celem budowanego modelu uczenia maszynowego jest stworzenie rozwiązania, które otrzymując jako wejście próbkę obrazu referencyjnego, będzie wskazywać najbardziej prawdopodobne położenie tego samego obszaru na zdjęciu dopasowywanym z innej daty. Danymi wejściowymi do trenowania są próbki pozyskane zgodnie z metodologią opisaną w sekcji powyżej. Odszukanie odpowiadających sobie obszarów jest traktowane jako problem klasyfikacyjny, stąd dla każdego kafelka wejściowego zwracane jest prawdopodobieństwo przynależności do wielu klas. Klasy te stanowią próbki z obrazu o dacie późniejszej. Kafelki o największym prawdopodobieństwie uznawany jest za odpowiadający obszar. Na podstawie współrzędnych środków zdjęć wyznaczane jest przesunięcie wzdłuż obu osi obrazu.

W pierwszym kroku skupiono się na dobraniu odpowiedniej architektury sieci, stąd przetestowano kilka prostych autorskich CNN oraz zaadoptowano rozwiązania istniejące, takie jak LeNet [40], AlexNet [41] czy też VGG-16 [42]. W ramach obliczeń testowych przeprowadzonych na obszarze lodowcowym zdecydowano, że największym potencjałem odznacza się architektura AlexNet, dla której dokonano dalszych testów parametrów. Własne architektury sieci wykazały niewystarczający stopień złożoności modelu, co skutkowało niepoprawnym identyfikowaniem par obrazów, a co za tym idzie wartościami przemieszczeń o bardzo niskiej wiarygodności. Architekturę VGG-16 odrzucono na tym etapie z uwagi na wysokie koszty czasowe oraz sprzętowe podczas trenowania modelu. Sieci AlexNet oraz LeNet wykazały podobną efektywność w testach, lecz to dla pierwszej z nich zaobserwowano większą stabilność w ramach kolejnych iteracji obliczeń. Architektury były oceniane poprzez generowanie map prędkości i wektorowych dla wybranego lodowca, stąd ocenie zostawały poddawane wiarygodność pozyskiwanych wartości oraz kierunku spływu lodu. W dalszym etapie architektura AlexNet została poddana bardziej szczegółowym analizom dla różnych wariantów parametrów uczenia. Testowano rodzaj optymalizatora: SGD (Stochastic Gradient Descent) oraz Adam (Adaptive Moment Estimation); rodzaj funkcji aktywacji: tanh (tangencja hiperboliczna) oraz ReLU (Rectified Linear Unit), a także tempo uczenia w zakresie od 0,0005 do 0,01. Ocena modelu odbywała się za pomocą sprawdzenia wiarygodności mapy prędkości oraz kierunku spływu lodu dla całego obszaru, oraz w sposób bardziej szczegółowy dla trzech rejonów lodowca. Do szczegółowych analiz wybrano kafelki leżące: w relatywnie stabilnym obszarze zdjęcia, w centralnej części jezora lodowcowego oraz w rejonie mniejszych prędkości. Dla wybranych rejonów dążono do maksymalizacji dokładności modelu, zminimalizowania funkcji straty, maksymalizacji prawdopodobieństwa oraz jak najmniejszego rozproszenia prawdopodobieństwa między klasami. Ostateczny model składa się z 5 warstw konwolucyjnych, 3 warstw agregacji, 5 warstw normalizacyjnych, 1 warstwy porzucenia (tzw. "dropout") oraz 2 warstw w pełni połączonych. W ramach przeprowadzonych testów do ostatecznego modelu wybrano optymalizator Adam, tempo uczenia wynoszące 0,001, funkcję aktywacji ReLU oraz 100 epok obliczeniowych z zapewnieniem zapisania najlepszych wag w procesie uczenia.

Filtracja i walidacja

W celu zapewnienia danych o możliwie największej wiarygodności wyniki pozyskane za pomocą CNN poddano dalszej filtracji. W pierwszym z kroków przeanalizowano rozkład prawdopodobieństw przypisywanych różnym klasom jako wynik działania modelu. Wyliczono średnią wartość prawdopodobieństwa (μ) oraz jego odchylenie standardowe (σ). Do dalszych analiz pozostawiono tylko i wyłącznie te kafelki, dla których zwrócona wartość prawdopodobieństwa maksymalnego przekroczyła wartość $\mu \pm 3\sigma$. Następnie wymaskowano obszary odpowiadające wodzie lub lodowi płynącemu, aby skupić się wyłącznie na analizie ruchu lodowca. W kolejnym z etapów odfiltrowano wszystkie kafelki z maksymalnym prawdopodobieństwem nieprzekraczającym 0,05. Tak odfiltrowane przemieszczenia przeliczono z pikseli na wartości metryczne za pomocą wielkości piksela terenowego. Maksymalne przemieszczenie zostało wyliczone jako wypadkowa przesunięć wzdłuż obu osi obrazów, a prędkości wyliczono na podstawie bazy czasowej pomiędzy kolejnymi zobrazowaniami SAR. Wartości te zostały poddane walidacji poprzez porównanie z prędkościami wyliczonymi dla tych samych zobrazowań za pomocą metody OT w oprogramowaniu teledetekcyjnym Gamma.

Rozdział 6

Wyniki i dyskusja


W niniejszym rozdziale przytoczono najważniejsze wyniki będące częścią omówionego w Rozdz. 3 cyklu publikacji. Wybrano wyłącznie te fragmenty analiz, które są kluczowe do osiągnięcia postawionych celów rozprawy doktorskiej. Zakres analiz znajduje się w załącznikach do rozprawy, które zawierają pełne teksty publikacji. W Rozdz. 6.1 skupiono się na porównaniu efektywności pasma C i pasma X radarów do analizy prędkości lodowców. Rozdział 6.2 skupia się na analizie wpływu bazy czasowej na dokładność wyników pozyskiwanych metodą OT. W kolejnej z części (Rozdz. 6.3) uwagę poświęcono wpływowi jednego z kluczowych parametrów wspomnianej metody, tj. optymalnej wielkości okna poszukiwawczego z analizą niepewności, którą obarczone są mapy wynikowe. Ostatnia sekcja (Rozdz. 6.4) skupia się na zaprezentowaniu wyników dla alternatywnej metody wyznaczania przemieszczeń poziomych dla lodowców, opartej na CNN. Efektywność zaproponowanej metody oceniono na bazie zarówno syntetycznych zbiorów danych, jak i analizy prędkości w warunkach rzeczywistych. Wyniki przeanalizowano również w porównaniu do istniejących metod teledetekcyjnych.

6.1 Ocena użyteczności danych ICEYE

W tej części analiz postawiono dwa główne cele: (1) ocenę możliwości wykorzystania zobrażeń satelitów ICEYE do monitorowania lodowca, oraz (2) porównanie efektywności pasma C i X do wyznaczania prędkości metodą OT. Do porównania wykorzystano po dwa obrazy radarowe pochodzące z misji S-1 oraz z satelity ICEYE, które pokrywają podobny okres. W przypadku pasma C wykorzystano 6-dniową bazę czasową oraz produkt Ground Range Detected (GRD) o rozdzielczości około 10 m. Dla danych z pasma X otrzymano dane w 4-dniowym odstępie czasowym i rozdzielczości 4-krotnie wyższej, wynoszącej około 2,5 m w obu kierunkach. Pierwszy z postawionych celów był kluczowy w przeprowadzanych analizach, gdyż w momencie publikowania artykułu nie istniały żadne dane potwierdzające użyteczność nowo dostarczanych danych z konstelacji ICEYE.


Wyniki obliczeń metodą OT przedstawiono osobno dla kierunku zasięgu, azymutalnego oraz dla maksymalnych prędkości i zestawiono je dla obu sensorów (Rys. 6.1). Wielkopowierzchniowy rozkład pola przemieszczeń jest podobny dla obu sensorów. Największe różnice w rozmieszczeniu i wielkości obserwowanych przemieszczeń zlokalizowano w okolicy czoła lodowca i w rejonach wokół zatoki. Są to jednocześnie obszary charakteryzujące się największymi prędkościami i zmiany tam zachodzą najintensywniej. W przypadku kierunku zasięgu radaru dla obu sensorów obserwowane są ujemne wartości w obrębie języka lodowcowego. W przypadku danych ICEYE obserwowane są wartości dodatnie dla obszaru poza głównym jęzorem. Dla danych S-1 w rejonie zatoki pojawiają się wartości dodatnie o dużej magnitudzie w północnej części obszaru, które prawdopodobnie są błędnie wyznaczone, na co szczególnie wskazuje mapa maksymalnych prędkości z przerwą ciągłością w tym samym rejonie. Dla kierunku azymutalnego widoczny jest podział na wartości ujemne i dodatnie dla obu sensorów. Dla maksymalnych prędkości ostateczna mapa wygląda w podobny sposób dla obu źródeł danych. Ponownie największe różnice obserwowane są w rejonie

czoła lodowca, gdzie rozkład przestrzenny przemieszczeń ulega delikatnym zmianom pomiędzy sensorami. W przypadku satelity ICEYE maksymalna prędkość w rejonie czoła lodowca wyniosła 41 m/dzień, a dla danych S-1 w podobnym rejonie zanotowano wartość maksymalną około 36 m/dzień.



Rysunek 6.1: Rozkład przemieszczeń w kierunkach zasięgu i azymutu oraz maksymalne prędkości uzyskane przy użyciu obrazów radarowych z satelitów ICEYE i S-1.


W celu dokładniejszej analizy otrzymanych wartości przemieszczeń i ich zbieżności między sensorami wydzielono 4 obszary do szczegółowych porównań. W każdym z obszarów dla wygenerowanej siatki punktów próbkowano wartości rastrowe zawierające informacje o przemieszczeniu i wykonano wykresy punktowe porównujące przemieszczenia z obu sensorów. Zgodność wyników oceniono za pomocą współczynnika determinacji R^2 (Rys. 6.2).



Rysunek 6.2: Wykresy korelacji dla wybranych części lodowca.


Zakresy zbadanych korelacji różnią się znacząco w zależności od wybranego obszaru, a także analizowanego kierunku przemieszczeń. Najbardziej spójne pomiary otrzymano dla obszaru 3, gdzie współczynnik determinacji oscylował w granicach 0,93-0,97. Współczynnik R^2 spadał wraz ze zbliżaniem się do czoła lodowca. Największe rozproszenie punktów zaobserwowano dla obszaru 4, obejmującego samo czoło lodowca. Największą zbieżność we wszystkich obszarach otrzymano dla kierunku azymutalnego. Wzdłuż osi lodowca poprowadzono dodatkowo profil mający na celu sprawdzenie zbieżności wyników między dwoma sensorami, który przedstawiono na Rys. 6.3. Przedstawiony wykres wykazuje, że prędkości wyznaczone za

pomocą danych z obu sensorów odznaczają się dużym podobieństwem. Obserwowane są nieliczne odchylenia w okolicach 3 km, 9 km i 30 km profilu. Widoczny jest jednak znaczący wzrost prędkości przy czole lodowca, który uwidocznił się na danych z satelitów ICEYE, a S-1 wykazuje tam wartości o kilka metrów na dobę niższe.




Rysunek 6.3: Prędkości wzdłuż profilu lodowca z danych S-1 i ICEYE.

Prócz wewnętrznej analizy spójności wyników pomiędzy pasmem C i X, wyniki porównano z niezależnymi danymi o prędkości pozyskanymi w ramach projektu GrIMP. Jest to dodatkowy element analiz porównawczych, który nie został uwzględniony w pierwotnym artykule, lecz został dodany w celu podniesienia wiarygodności wyników. Z bazy GrIMP pobrano raster dla odpowiadającego obszaru i zakresu czasowego zawierającego średnie prędkości dla lodowca Jakobshavn. Na obszarze całego lodowca i jego otoczenia wygenerowano regularną siatkę punktów, dla której próbkowano wartości rastrowe z obu sensorów i z projektu GrIMP. Następnie zbadano korelację pomiędzy danymi GrIMP a danymi ICEYE i S-1, tworząc macierz korelacji (Rys. 6.4). Wszystkie współczynniki korelacji odznaczają się bardzo wysokim poziomem. Największą korelację na poziomie 0,98 zaobserwowano pomiędzy danymi GrIMP a danymi S-1. Niemniej jednak wyniki z sensora ICEYE są spójne z danymi GrIMP na poziomie 0,97. Dodatkowo analizując większą obszarowo siatkę punktów niż w przypadku Rys. 6.2, wykraczającą również poza obszar jezora lodowcowego, korelacja pomiędzy dwoma sensorami wyniosła aż 0,96. Świadczy to o tym, że na obszarach relatywnie stabilnych oba sensory dostarczają bardziej spójnych wartości. Pomimo nieznacznie niższego współczynnika korelacji dla danych ICEYE, warto zwrócić uwagę na to, że produkt GrIMP dostarcza mapy prędkości głównie na podstawie danych S-1, co może wpływać na wyższy stopień korelacji właśnie dla tego sensora. Niemniej jednak wykazane porównania wskazują jednoznacznie, że dane z pasma X dostarczają wiarygodnych informacji pod kątem przemieszczeń poziomych. Nie zauważono jednak znaczącej poprawy wyników poza rejonem czoła lodowca dla danych o wyższej rozdzielczości.



Rysunek 6.4: Macierz korelacji dla prędkości z obu sensorów i produktu GrIMP.

Z uwagi na brak znaczącej różnicy jakościowej dla pozyskanych map prędkości, porównaniu poddano również same obrazy amplitudy dostarczane przez oba sensory (Rys. 6.5). Obraz amplitudy z sensora ICEYE pozwala na uchwycenie znacznie większej ilości szczegółów terenowych, które mogą pozwolić na dokładniejsze dopasowanie zdjęć w metodzie OT. Na obrazie z S-1 część szczegółów ulega rozmyciu, przez co trudniejsze do uchwycenia są m.in. szczeliny czy pęknięcia powstające w pobliżu lodowca z uwagi na wysokie prędkości w tym rejonie. Ponadto na zobrazowaniu ICEYE lepiej widoczne są granice między czołem lodowca a lodem pływającym w zatoce, czy też pobliskimi skałami, a materiał lodowy pływający w zatoce jest łatwiej rozróżnialny. Informacje te mogą ułatwić m.in. mapowanie linii czoła lodowca czy monitorowanie lodu morskiego. Pomimo braku znaczących różnic w mapach prędkości dostarczonych na tym poligonie, można wnioskować, że szczegółowość uchwycona przez sensor ICEYE może być szczególnie użyteczna w mapowaniu lodowców o mniejszych prędkościach lub zasięgu przestrzennym. Wówczas mniejszy piksel terenowy i zdolność do wychwytywania drobnych różnic na powierzchni lodowca mogą pozwolić na zarejestrowanie mniejszej skali ruchów, niż w przypadku sensora S-1, co może się okazać szczególnie przydatne w przypadku lodowców górskich oraz Svalbardu, gdzie rejestrowane prędkości mają znacznie niższe wartości.




Rysunek 6.5: Obraz amplitudy dla sensora ICEYE (a) oraz S-1 (b) dla zdjęć z dnia 09.01.2021 r.

6.2 Ocena wpływu bazy czasowej

Niniejsza część została poświęcona analizie wpływu długości bazy czasowej pomiędzy kolejnymi zobrazeniami radarowymi na jakość map prędkości pozyskiwanych metodą OT. W tym celu skupiono się na porównaniu map prędkości dla lodowca Jakobshavn dla danych S-1 zarejestrowanych dla krótkiej (6-dniowej) i długiej (24/30-dniowej) bazy czasowej. Prócz oceny wizualnej jakości wyników, w kolejnym etapie sprawdzono wiarygodność wyznaczonych wielkości poprzez porównanie z niezależnym zbiorem danych GrIMP. Porównanie przeprowadzono dla siatki punktów rozmieszczonych w obrębie całego lodowca.


W przypadku danych z lutego 2017 r. porównano 6- i 24-dniowe bazy czasowe. Dla dłuższego okresu otrzymano niedoszacowane wartości prędkości oraz brak ciągłości w pomiarze w jednym z rejonów lodowca. Mapa dla 6-dniowej bazy charakteryzuje się brakiem szumów, o czym świadczą zerowe wartości prędkości poza głównym jeziorem lodowca. Dla danych z bazy 24-dniowej widoczne są szumy, szczególnie w północno-wschodniej części obszaru oraz na granicy lodowca, bliżej jego ujścia do zatoki. W porównaniu z danymi prędkościowymi z bazy GrIMP współczynnik determinacji porównujący dane z krótkiej bazy czasowej z danymi referencyjnymi wyniósł 0,67. Z kolei dla długiej bazy czasowej współczynnik ten spadł aż do poziomu 0,25, co świadczy o spadku o ponad 0,4 przy 4-krotnym zwiększeniu bazy czasowej.



Rysunek 6.6: Prędkości dla zimy 2017 uzyskane z krótkich (a) i długich (c) baz czasowych wraz z wykresami korelacjami (b, d) odniesionymi do bazy GrIMP.

Dla danych dla sierpnia 2017 r. porównano ze sobą mapy wygenerowane dla 6- i 30-dniowej bazy czasowej. Dla krótkiej bazy czasowej obserwowane są większe prędkości, szczególnie bliżej czoła lodowca. Dla dłuższej bazy czasowej, wraz ze zbliżaniem się do czoła lodowca, dochodzi do zaburzenia sygnału i w okolicach ujścia do zatoki nie jest możliwe wyznaczenie wiarygodnych wartości. Dłuższa baza czasowa charakteryzuje się licznymi szumami w północnej i wschodniej części obszaru, gdzie powinny znajdować się relatywnie stabilne rejony. Prawdopodobnie z uwagi na wyższe temperatury pokrywa śnieżna ulega tam topnieniu, przez co charakterystyka odbicia sygnału w tamtych rejonach ulega znaczącym zmianom. Dla bazy 6-dniowej porównanie z bazą GrIMP wykazało współczynnik determinacji na poziomie 0,78. W przypadku danych o długiej bazie czasowej punkty ulegają tak dużemu rozproszeniu, że nie jest możliwe zaobserwowanie żadnego trendu i korelacji pomiędzy danymi.

Analizując wyniki dla obu pór roku, widać, że najtrudniejszym rejonem dla długich baz czasowych okazuje się rejon czoła lodowca, gdzie prędkości osiągają największe wartości. Oznacza to, że szczególnie w rejonach o wysokiej dynamice ruchów nie jest zalecane stosowanie długich baz czasowych, a najlepsza jakość map końcowych, ze zredukowanymi szumami, jest możliwa do osiągnięcia w krótszych bazach czasowych. Wydłużanie bazy czasowej powoduje znaczący spadek w jakości dostarczanych wielkości prędkości lodowców, co widoczne jest poprzez znaczny spadek współczynnika determinacji przy porównaniu do danych referencyjnych. Dodatkowym aspektem widocznym przy porównaniu wszystkich map jest widoczna zwiększona ilość szumów w okresie letnim w stosunku do zimowego. Jest to prawdopodobnie związane ze zmieniającą się pokrywą lodowcową, która latem jest bardziej wrażliwa na zmiany pogodowe i temperatury, co skutkuje dekorelacją sygnału.




Rysunek 6.7: Prędkości dla lata 2017 uzyskane z krótkich (a) i długich (c) baz czasowych raz z wykresami korelacjami (b,d) odniesionymi do bazy GrIMP.

6.3 Ocena wpływu rozmiaru okna poszukiwawczego

Kolejny etap analiz został poświęcony analizie jednego z kluczowych parametrów metody OT, jakim jest wielkość tzw. okna poszukiwawczego. Parametr ten określa rozmiar fragmentów obrazów, które porównywane są ze sobą w poszukiwaniu maksymalnej wartości NCC. W celu określenia wpływu tego parametru na wiarygodność map przemieszczeń poziomych, pozyskiwanych metodą OT, skupiono się na stosunkowo niewielkim obiekcie, jakim jest osuwisko Ponzano, zlokalizowane w centralno-wschodniej części Włoch. Z uwagi na znaczącą dynamikę ruchów tego obszaru i spływ materiału głównie w kierunku poziomym, jest to bardzo dobry poligon do testowania wpływu parametrów metody OT na uzyskiwany obraz pola przemieszczeń. W pierwszym etapie wykonano wstępne obliczenia dla okresu głównej fazy ruchów osuwiska zarówno na bazie danych S-1, jak i TSX, w celu oceny możliwości wykorzystania obu sensorów. W następnym etapie, z uwagi na relatywnie niewielki obszar osuwiska, analizę rozmiaru okna poszukiwawczego oparto wyłącznie o zobrazowania wysokorozdzielcze w celu pozyskania wyników o możliwie najwyższej dokładności.


Wyniki obliczeń metodą OT dla zobrazowań S-1 o 12-dniowej bazie czasowej zaprezentowano osobno dla kierunku azymutalnego, zasięgu oraz dla maksymalnych wartości przemieszczeń (Rys. 6.8). Dla kierunku zasięgu maksymalne przemieszczenie w dolnej części osuwiska wyniosło 9 m, a w górnej części zaobserwowano maksymalne wartości na poziomie 8 m. Na mapach reprezentujących przemieszczenia maksymalne i dla kierunku zasięgu widoczne są rozmyte granice osuwiska. Niemniej jednak, poza granicami osuwiska obserwowane są znaczące szumy, które sugerują ruchy na poziomie kilku metrów, co podważa

wiarygodność wyników pozyskiwanych z pomocą danych S-1. W przypadku wyników dla kierunku azymutalnego niemożliwe jest wiarygodne określenie przemieszczeń terenu, co spowodowane jest niższą rozdzielczością obrazów dla tego kierunku. Biorąc pod uwagę pozyskane wyniki, do dalszych analiz konieczne jest zaaplikowanie danych o wyższej rozdzielczości. Przedstawione wyniki wskazują na ograniczone możliwości wykorzystania danych S-1 do analizy dynamicznych ruchów o mniejszym zasięgu przestrzennym.



Rysunek 6.8: Wartości przemieszczenia obliczone w okresie 06/02/2017-18/02/2017 na podstawie obrazów S-1.


Wpływ rozmiaru okna poszukiwawczego oceniono na mapach wykonanych dla 8 różnych kombinacji, analizując średnie wartości ruchów i odchylenia w buforach wokół osuwiska. Zarówno dla bufora 200 m, jak i 1000 m otrzymano podobne wyniki. Nieznacznie wyższe wartości średnie oraz odchylenie zaobserwowano dla bufora 1000 m. Analizując Rys. 6.9 widać, że wraz ze zmniejszaniem okna poszukiwawczego zarówno średnie przemieszczenie, jak i jego odchylenie się zwiększają. Wartości zmierzają ku zeru wraz z powiększaniem rozmiaru okna poszukiwawczego. Tendencje te są zbliżone zarówno dla przemieszczeń na kierunku azymutalnym, jak i na kierunku zasięgu. Analiza wskazuje, że zbyt mała wielkość okna poszukiwawczego powoduje przede wszystkim większe zaszumienie wyników, a także spadek dokładności metody obliczeniowej. Dzieje się tak, ponieważ skupiając się na relatywnie niewielkim fragmencie zdjęcia, często trudno jest objąć nim obszar wykazujący charakterystyczne cechy wizualne, które ułatwiałyby dopasowanie zdjęć. Zwiększanie okna poszukiwawczego pomaga w zniwelowaniu błędów spowodowanych błędnymi dopasowaniami, lecz prowadzi do znacznego wygładzenia wyników. Z tego względu na otrzymywanych mapach przemieszczeń widoczne jest mniej detali, które mogą okazać się kluczowe dla analizy obserwowanego zjawiska.




Rysunek 6.9: Rozmiar okna poszukiwawczego, a jakość wyników.

Problem występowania szumów przy stosowaniu małych okien, a z drugiej strony utraty detali przy wykorzystaniu dużych okien poszukiwawczych, widoczny jest na Rys. 6.10 dla kierunku zasięgu i na Rys. 6.11 dla kierunku azymutalnego. Jako wartość optymalną, stanowiącą kompromis między dokładnością a szczegółowością map, wybrano okna poszukiwawcze o wielkości 64×64 pxl. Badania przeprowadzone przez innych badaczy również potwierdzają, iż stosowanie mniejszych rozmiarów okien nie jest zalecane w metodzie OT [43, 44]. Otrzymane dla tej wartości średnie odstępstwa od płaszczyzny zerowej są nieznacznie większe od 0 cm, przy odchyleniach oscylujących w okolicach $\pm 0,39$ m w kierunku zasięgu i $\pm 0,61$ m

w kierunku azymutalnym. Wartości te stanowią ok. 25% wielkości piksela terenowego zastosowanych zobrazowań SAR i mogą świadczyć o wewnętrznej dokładności algorytmu OT. Warto jednak zwrócić uwagę, że powyższe analizy zostały przeprowadzone na surowych danych bez filtrowania za pomocą progu NCC danych o słabszym dopasowaniu, co podniosłoby dokładność wyników. Stosowanie mniejszych okien poszukiwawczych jest zatem niezalecane, gdyż znaczące szумы występujące poza strefą ruchów podważają wiarygodność pozyskanych wyników. W przypadku obszarów o większej powierzchni korzystne może być zastosowanie większych okien poszukiwawczych, gdzie stopień szczegółowości nie jest aż tak kluczowy w analizie ruchów.



Rysunek 6.10: Mapy przemieszczeń na kierunku zasięgu radaru w zależności od rozmiaru okna poszukiwawczego.




Rysunek 6.11: Mapy przemieszczeń na kierunku azymutalnym w zależności od rozmiaru okna poszukiwawczego.

6.4 Zastosowanie CNN do pomiaru przemieszczeń

Poprawność działania modelu zaproponowanego w Rodz. 5.4 przetestowano zarówno dla sztucznie przesuniętych obrazów, jak i w warunkach rzeczywistego spływu lodowca. Testy dla manualnie przesuniętych obrazów przeprowadzono dla zdjęcia kota oraz pojedynczego obrazu amplitudy dla lodowca Dagaard-Jensen, symulując przesunięcie całego obrazu. Testy w warunkach rzeczywistych przeprowadzono dla lodowca Dagaard-Jensen, analizując cztery kolejne zobrażenia S-1 i wyznaczając prędkości w najkrótszych bazach czasowych.


Pierwszy z zestawów testowych składający się ze zdjęcia kota został przesunięty wzdłuż osi X i Y o wektor $[-10, -8]$ wyrażony w pikselach. Obraz przed przesunięciem uznano za obraz referencyjny, a obraz przesunięty jako zdjęcie dopasowywane. Dzięki temu znane jest dokładne przesunięcie szukane wzdłuż obu osi, a co za tym idzie, możliwa jest ocena poprawności działania algorytmu. Ponadto zdecydowano się na wykonanie pierwszych testów na obrazie nie pochodzącym z radaru, aby ułatwić wizualną ocenę wyników i określenie potencjału zaproponowanej metodyki. Rysunek 6.12 pokazuje wyniki pozyskane za pomocą CNN dla tego zestawu testowego. Wyznaczone kierunki przesunięć są zgodne z oczekiwanym wektorem.

Nieliczne wektory wykazują nieznaczne zaburzenia w kierunku przesunięcia. Analiza prawdopodobieństw, z jakimi zostały zwrócone poszczególne wartości, wskazuje na dużą pewność modelu w wyznaczaniu przemieszczeń. Znacząca większość kafelków została zidentyfikowana z prawdopodobieństwem ponad 0,95. Rozkłady wykrytych przesunięć z podziałem na oś X i Y wskazują, że ok. 81% wszystkich kafelków zostało wykrytych bezbłędnie, a kolejne 6% wszystkich kafelków zostało wykrytych z błędem ± 1 piksel. Największe rozbieżności zauważono w prawym górnym narożniku analizowanego obrazu z uwagi na jednolity kolor analizowanych kafelków oraz brak cech charakterystycznych, które pozwalałyby na jednoznaczną identyfikację odpowiednich fragmentów obrazu w tym rejonie.



Rysunek 6.12: Wyniki dla testowego zestawu danych nr 1: (A) kierunek przesunięcia oszacowany przez CNN, (B) maksymalne prawdopodobieństwo z modelu ML, (C) wykryte przesunięcie wzdłuż osi X, (D) wykryte przesunięcie wzdłuż osi Y.


Drugi z zestawów testowych zawierający zdjęcie amplitudy lodowca Daugaard-Jensen z dnia 03.02.2024 r. został manualnie przesunięty o wektor [3,8] wyrażony w pikselach. Przeprowadzono analogiczne analizy, jak dla poprzedniego zestawu danych. Podobnie jak we wcześniejszym przypadku ogólny kierunek przesunięcia jest zgodny z założonym wektorem (Rys. 6.13). Na mapie prawdopodobieństw widoczne jest, że w rejonach poza głównym jeziorem lodowcowym otrzymano bardzo wysokie prawdopodobieństwa świadczące o dużej pewności modelu powyżej 0,95. Niższe wartości prawdopodobieństw obserwowane są w rejonie samego jezera, co może świadczyć o niewielu cechach charakterystycznych, które udało się zidentyfikować w tym rejonie. Analiza przesunięć wzdłuż obu osi wykazała, że ok. 90,3% wszystkich kafelków zostało zidentyfikowanych poprawnie, 8,1% z błędem ± 1 piksel, a tylko 4 kafelki sklasyfikowano z błędem przekraczającym 1 piksel.




Rysunek 6.13: Wyniki dla testowego zestawu danych nr 2: (A) kierunek przesunięcia oszacowany przez CNN, (B) maksymalne prawdopodobieństwo z modelu ML, (C) wykryte przesunięcie wzdłuż osi X, (D) wykryte przesunięcie wzdłuż osi Y.

Satysfakcjonujące wyniki testów na zbiorach testowych wykazały, że zaproponowane podejście umożliwia prawidłową detekcję przesunięć dla pary dowolnych obrazów. Z tego względu, kolejne testy przeprowadzono w rejonie lodowca Daugaard-Jensen, wykorzystując 4 obrazy amplitudy dla zdjęć S-1. Zobrazowania były analizowane parami, tworząc 12-dniowe bazy czasowe, dzięki czemu wygenerowano 3 mapy prędkości wraz z kierunkami przemieszczenia (Rys. 6.14). Jako dane wejściowe do modelu wykorzystano współrejestrowane w oparciu o NMT zobrazowania SAR. Dla wszystkich trzech okresów obliczeniowych maksymalne prędkości wyniosły w okolicach 10-11 m/dzień, z pojedynczymi kafelkami o wartościach do 13 m/dzień. Poza jeźorem lodowcowym obszar jest relatywnie stabilny z przemieszczeniami na poziomie 0-1 m/dzień. Mapy wektorowe wskazują na poprawny spływ lodowca, zakładając, że naturalny ruch lodowca odbywa się w kierunku ku zatoce. Poprawne kierunki i wartości rejestrowane są również w rejonie bliżej czoła lodowca, gdzie obserwowany materiał przemieszcza się najszybciej. Niemniej jednak pojawiają się na mapach pojedyncze wektory wskazujące nieliniarny przepływ lodowca oraz kafelki z niewielkimi wartościami ruchów w obrębie jezora, które powinny zostać poddane dalszej filtracji i prawdopodobnie stanowią błędy obliczeniowe, których w zaproponowanej metodzie nie udało się odseparować.

Analizę dokładności zaproponowanej metody przeprowadzono na bazie porównania z wynikami pozyskanymi metodą OT dla tych samych zobrazowań radarowych. Na Rys. 6.15 przedstawiono mapy prędkości pozyskane za pomocą metody OT, różnice pomiędzy wartościami wyliczonymi metodą OT i za pomocą CNN w formie map przestrzennych oraz w formie histogramów ukazujących rozkład tych różnic. Na podstawie obliczonych średnich różnic między dwoma metodami oraz odchyłeń standardowych oszacowano dokładność metody. Mapy prędkości pozyskane za pomocą metody OT dla wszystkich trzech okresów wskazują na zerowe wartości przemieszczeń poza obszarem lodowca. Maksymalne zarejestrowane prędkości wynoszą 10 m/dzień przy czole lodowca. Średnie prędkości w obrębie jezora oscylują głównie w zakresie 5-9 m/dzień. Różnice prędkości pomiędzy dwoma metodami w kolejnych okresach poddanych analizie wynoszą $1,0 \pm 2$ m/dzień, $0,7 \pm 1,7$ m/dzień oraz $0,8 \pm 1,6$ m/dzień. Analizowane w przypadku modelu CNN obrazy posiadają piksel terenowy o wielkości ok. 10 m, stąd w wybranej bazie czasowej błąd na poziomie 1 piksela odpowiada błędowi w prędkości na poziomie około 0,8 m/dzień. W zakresie 2-pikselowego błędu w wyznaczeniu prędkości sklasyfikowano odpowiednio dla każdego z okresów 76%, 79% oraz 77% próbek. Dokładność na poziomie ± 2 piksele na tym etapie budowania metodologii jest wystarczająca i wykazuje potencjał zaproponowanej metodologii. Szczególnie w przypadku zestawów testowych, jak i w rejonach stabilnych uwidacznia się poprawność działania stworzonego algorytmu. W przypadku głównego jezora lodowcowego aktualna dokładność jest niższa, prawdopodobnie z uwagi na brak cech charakterystycznych na obrazach SAR w tym rejonie, co skutkuje mniejszą skutecznością w poprawnym klasyfikowaniu kafelków. Ponadto dodatkową trudnością może być znaczące deformowanie się przypowierzchniowej warstwy lodowca, które może zmieniać tym samym swój wygląd pomiędzy kolejnymi zdjęciami, a także rozmarzanie górnej warstwy lodowca czy też świeże opady śniegu, które mogą prowadzić do dekorelacji sygnału między obrazami i wizualnej zmiany interpretowanego obszaru.



Rysunek 6.14: Wyniki obliczeń opartych na CNN dla lodowca Dagaard-Jensen dla 3 okresów: (A,C,E) mapy wektorowe kierunku ruchu lodowca i (B,D,F) średnie prędkości [m/dzień].



Rysunek 6.15: Prędkości lodowca Dugaard-Jensen obliczone przez algorytm OT (A-C), różnice między prędkościami OT i CNN (D-F) oraz histogramy tych różnic (G-I).

Rozdział 7

Podsumowanie

Monitorowanie kondycji lodowców, w tym ich prędkości, jest kluczowe w kontekście poprawnego modelowania pokryw lodowcowych i lepszego zrozumienia odpowiedzi kriosfery na globalne zmiany klimatyczne. Z uwagi na wyizolowanie obszarów polarnych oraz ich znaczące zakresy powierzchniowe, dane satelitarne, w tym dane radarowe, są głównym źródłem danych na temat kondycji tych rejonów. Z tego względu ważne jest również opracowanie możliwie szybkich i dokładnych metod przetwarzania danych, m.in. do monitorowania prędkości poruszania się lodowców. Obecnie istnieją rozwiązania pozwalające na dostarczenie informacji o przemieszczeniach poziomych na podstawie danych SAR, które bazują głównie na wykorzystaniu korelacji krzyżowej. Niemniej jednak dokładność pozyskiwanych wyników zależy od wielu czynników, takich jak jakość danych wejściowych czy też parametry przetwarzania. Niniejsza praca miała na celu zbadanie wpływu wybranych czynników na poprawność wyznaczania prędkości lodowców, a także zdefiniowanie optymalnych parametrów do przetwarzania danych metodą OT. Co więcej, biorąc pod uwagę intensywny rozwój technik sztucznej inteligencji i rosnące możliwości analizy obrazów, głównym celem rozprawy było opracowanie alternatywnej metody określania przemieszczeń poziomych na podstawie satelitarnych zobrażeń radarowych oraz CNN.

Wyniki przeprowadzonych badań wykazały po raz pierwszy, że wysokorozdzielcze dane z pasma X pochodzące z satelitów ICEYE mogą być wykorzystywane do monitorowania prędkości lodowców. Zgodność wyników z niezależnymi zbiorami danych wyniosła 97%. Podobne wyniki otrzymano dla lodowca Jakobshavn w Grenlandii dla ogólnodostępnych danych z satelitów S-1. Wykazuje to wysoką zgodność obu sensorów pomimo różnic w rozdzielczości. Analizy wykazały jednak znacznie większy stopień szczegółowości danych w paśmie X w okolicach czoła lodowca. Sugeruje to, że wysokorozdzielcze dane mogą być wykorzystywane nie tylko do monitorowania dynamicznych ruchów, jak w przypadku analizowanego lodowca, ale mogą osiągać potencjalnie lepsze wyniki w rejonach o mniejszej powierzchni czy mniejszej prędkości ruchów w porównaniu do pasma C. Przypuszczenia te zostały potwierdzone badaniami przeprowadzonymi w innym rejonie świata, na osuwisku w Ponzano, we Włoszech. W przypadku rejonu o znacznie mniejszym rozmiarze powierzchniowym i mniejszej skali ruchów detekcja przemieszczeń poziomych za pomocą pasma C była niemożliwa, podczas gdy wysokorozdzielcze zobrażenia z satelitów TSX (pasmo X) dostarczyły wiarygodnych wyników, potwierdzając zwiększenie dokładności metody OT ze zmianą sensora.

Przeprowadzone na bazie wysokorozdzielczych danych testy rozmiarów okien poszukiwawczych wykazały, że optymalny rozmiar to minimum 64×64 piksele. Mniejsze okna poszukiwawcze skutkują znaczącą ilością szumów oraz zwiększaniem błędów wyznaczania przemieszczeń, co skutkuje obniżeniem wiarygodności obliczeń. Większe okna poszukiwawcze mogą dostarczać wiarygodnych wyników w rejonach o znacznie większych zasięgach powierzchniowych, gdzie precyzyjna informacja o ruchach nie jest wymagana, gdyż zwiększanie rozmiaru okna poszukiwawczego skutkuje znaczącym wygładzaniem pozyskiwanych danych, w tym zniekształceniem lub zdeformowaniem linii wyznaczającej granicę występowania

ruchów powierzchni terenu. Analiza szumów wokół badanego obiektu wykazała dokładność metody OT na poziomie $\pm \frac{1}{4}$ piksela terenowego.

Badanie wpływu długości bazy czasowej na jakość pozyskiwanych wyników wykazało znaczącą przewagę krótkich baz czasowych przy analizie prędkości lodowców. Zmniejszenie bazy czasowej zarówno dla okresu letniego, jak i zimowego przyniosło poprawę wyników dla metody OT. Dla danych zimowych współczynnik korelacji z niezależnym zbiorem danych wzrósł z 0,25 do 0,67 dla 4-krotnego zmniejszenia bazy czasowej. W miesiącach letnich dłuższa baza czasowa (30 dni) nie pozwoliła na pozyskanie wiarygodnych wartości ruchów, gdzie dla 6-dniowej bazy czasowej współczynnik determinacji wyniósł 0,78.

Zaproponowana nowa metodyka wyznaczania przemieszczeń poziomych z wykorzystaniem CNN jako jedna z nielicznych w aktualnym stanie wiedzy wykorzystuje w swoim podejściu wyłącznie dane SAR. Ponadto opracowane rozwiązanie nie wymaga dodatkowego przetwarzania danych w celu trenowania modelu, co upraszcza korzystanie z dostępnych narzędzi SI. Pomimo wykorzystania znanych metod augmentacji danych czy też bazowania na istniejących architekturach CNN, po raz pierwszy narzędzia te zostały zaadoptowane do monitorowania ruchów poziomych na zdjęciach satelitarnych. Co więcej, przeprowadzone testy i analizy pozwoliły na osiągnięcie bardzo wysokiej dokładności dla zestawów testowych. W zakresie błędu ± 1 piksel zidentyfikowano 87% wszystkich kafelków dla manualnie przesuniętego obrazu kota oraz 98% kafelków dla manualnie przesuniętego obrazu amplitudy lodowca Daugaard-Jensen. Metoda została także przetestowana w warunkach rzeczywistych dla lodowca Daugaard-Jensen, analizując 4 kolejne zobrażenia radarowe. Pozyskiwane mapy prędkości są zgodne z wynikami metody OT ze średnim błędem na poziomie ± 2 piksele. Dodatkowo analiza uzyskanych wyników potwierdza stabilność opracowanej metody i zgodność z naturalnym kierunkiem spływu lodowca. Największe dokładności otrzymano w rejonach relatywnie stabilnych, natomiast w obrębie głównego jeziora lodowcowego zróżnicowanie jest większe z uwagi na brak charakterystycznych elementów pokrywy lodowcowej, która ułatwiłaby identyfikację podobnych obszarów na obu zdjęciach. Niemniej jednak przeprowadzone testy potwierdzają, że zaproponowane rozwiązanie pozwala na poprawne wyznaczanie przesunięć pomiędzy dwoma obrazami, w tym na wyznaczenie przemieszczeń na bazie obrazów radarowych.

Podsumowując, zaproponowane podejście stanowi autorskie rozwiązanie problemu wyznaczania przemieszczeń poziomych lodowców z użyciem uczenia maszynowego. Przedstawiona metodyka po raz pierwszy wykorzystwała architekturę sieci konwolucyjnych AlexNet do pracy z obrazami radarowymi i została dostosowana do problemu określenia wartości przemieszczeń między obrazami. Zaproponowane wyniki są zatem potwierdzeniem tezy, że zastosowanie algorytmów uczenia maszynowego do analizy satelitarnych zobrażeń radarowych pozwala skutecznie monitorować przemieszczenia poziome lodowców. Potencjał zaprezentowanych wyników wykazuje konieczność dalszego rozwoju badań w kierunku znalezienia bardziej efektywnego i szybszego sposobu na detekcję ruchów poziomych w oparciu o alternatywne metody uczenia maszynowego. Co więcej, dalsze badania powinny uwzględnić również możliwość zaaplikowania jednego algorytmu do analizy nie tylko obrazów radarowych, ale także obrazów optycznych czy multi-spektralnych niezależnie od wielkości piksela terenowego. Pozwoliłoby to na opracowanie uniwersalnego algorytmu monitorowania przemieszczeń poziomych.

Bibliografia

- [1] McColl, S. T. (2015) Chapter 2 - Landslide Causes and Triggers, Hazards and Disasters Series Academic Press, Boston.
- [2] Jania, J. (1997) Glacjologia: nauka o lodowcach, Wydaw. Naukowe PWN, .
- [3] Colgan, W., Rajaram, H., Abdalati, W., McCutchan, C., Mottram, R., Moussavi, M. S., and Grigsby, S. (2016) Glacier crevasses: Observations, models, and mass balance implications. *Reviews of Geophysics*, **54**(1), 119–161.
- [4] Bamber, J. L., Westaway, R. M., Marzeion, B., and Wouters, B. (jun, 2018) The land ice contribution to sea level during the satellite era. *Environmental Research Letters*, **13**(6), 063008.
- [5] Scheuchl, B., Mouginot, J., and Rignot, E. (2012) Ice velocity changes in the Ross and Ronne sectors observed using satellite radar data from 1997 and 2009. *The Cryosphere*, **6**(5), 1019–1030.
- [6] Dirscherl, M., Dietz, A. J., Dech, S., and Kuenzer, C. (2020) Remote sensing of ice motion in Antarctica – A review. *Remote Sensing of Environment*, **237**, 111595.
- [7] Kääb, A., Winsvold, S. H., Altena, B., Nuth, C., Nagler, T., and Wuite, J. (2016) Glacier Remote Sensing Using Sentinel-2. Part I: Radiometric and Geometric Performance, and Application to Ice Velocity. *Remote Sensing*, **8**(7).
- [8] Solgaard, A., Kusk, A., Merryman Boncori, J. P., Dall, J., Mankoff, K. D., Ahlstrøm, A. P., Andersen, S. B., Citterio, M., Karlsson, N. B., Kjeldsen, K. K., Korsgaard, N. J., Larsen, S. H., and Fausto, R. S. (2021) Greenland ice velocity maps from the PROMICE project. *Earth System Science Data*, **13**(7), 3491–3512.
- [9] Hansen, R. (2001) Radar Interferometry. Data Interpretation and Error Analysis, Kluwer Academic Publishers, .
- [10] Scambos, T. A., Dutkiewicz, M. J., Wilson, J. C., and Bindschadler, R. A. (12, 1992) Application of image cross-correlation to the measurement of glacier velocity using satellite image data. *Remote Sensing of Environment*, **42**, 177–186.
- [11] Bindschadler, R. A. and Scambos, T. A. (4, 1991) Satellite-Image-Derived Velocity Field of an Antarctic Ice Stream. *Science*, **252**, 242–246.
- [12] Fan, J., Wang, Q., Liu, G., Zhang, L., Guo, Z., Tong, L., Peng, J., Yuan, W., Zhou, W., Yan, J., Perski, Z., and Sousa, J. (2019) Monitoring and Analyzing Mountain Glacier Surface Movement Using SAR Data and a Terrestrial Laser Scanner: A Case Study of the Himalayas North Slope Glacier Area. *Remote Sensing*, **11**, 625.

- [13] Fiorentini, N., Maboudi, M., Leandri, P., Losa, M., and Gerke, M. (12, 2020) Surface Motion Prediction and Mapping for Road Infrastructures Management by PS-InSAR Measurements and Machine Learning Algorithms. *Remote Sensing 2020, Vol. 12, Page 3976*, **12**, 3976.
- [14] Shami, S., Shahriari, M. A., Nilfouroushan, F., Forghani, N., Salimi, M., and Reshadi, M. A. M. (8, 2024) Surface displacement measurement and modeling of the Shah-Gheyb salt dome in southern Iran using InSAR and machine learning techniques. *International Journal of Applied Earth Observation and Geoinformation*, **132**, 104016.
- [15] (9, 2022) Application of Machine Learning in Forecasting the Impact of Mining Deformation: A Case Study of Underground Copper Mines in Poland. *Remote Sensing 2022, Vol. 14, Page 4755*, **14**, 4755.
- [16] Mirmazloumi, S. M., Gambin, A. F., Palamà, R., Crosetto, M., Wassie, Y., Navarro, J. A., Barra, A., and Monserrat, O. (8, 2022) Supervised Machine Learning Algorithms for Ground Motion Time Series Classification from InSAR Data. *Remote Sensing 2022, Vol. 14, Page 3821*, **14**, 3821.
- [17] Brengman, C. M. and Barnhart, W. D. (3, 2021) Identification of Surface Deformation in InSAR Using Machine Learning. *Geochemistry, Geophysics, Geosystems*, **22**, e2020GC009204.
- [18] Confuorto, P., Medici, C., Bianchini, S., Soldato, M. D., Rosi, A., Segoni, S., and Casagli, N. (4, 2022) Machine Learning for Defining the Probability of Sentinel-1 Based Deformation Trend Changes Occurrence. *Remote Sensing 2022, Vol. 14, Page 1748*, **14**, 1748.
- [19] (2, 2024) A novel machine learning and deep learning semi-supervised approach for automatic detection of InSAR-based deformation hotspots. *International Journal of Applied Earth Observation and Geoinformation*, **126**, 103611.
- [20] (1, 2018) Detecting Glacier Surface Motion by Optical Flow. *Photogrammetric Engineering and Remote Sensing*, **84**, 33–42.
- [21] Vogel, C., Bauder, A., Schindler, K., Sensing, R., and Zürich, E. (7, 2012) OPTICAL FLOW FOR GLACIER MOTION ESTIMATION. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, **I-3**, 359–364.
- [22] Altena, B. and Kääh, A. (6, 2017) Weekly glacier flow estimation from dense satellite time series using adapted optical flow technology. *Frontiers in Earth Science*, **5**, 254101.
- [23] Shen, H., Zhou, S., Fang, L., and Yang, J. (10, 2022) Glacier Motion Monitoring Using a Novel Deep Matching Network with SAR Intensity Images. *Remote Sensing 2022, Vol. 14, Page 5128*, **14**, 5128.
- [24] Kim, J., Jung, H. S., and Lu, Z. (3, 2025) Ground surface displacement measurement from SAR imagery using deep learning. *Remote Sensing of Environment*, **318**, 114577.
- [25] Łukosz, M. A., Hejmanowski, R., and Witkowski, W. T. (6, 2021) Evaluation of ICEYE Microsatellites Sensor for Surface Motion Detection—Jakobshavn Glacier Case Study. *Energies 2021, Vol. 14, Page 3424*, **14**, 3424.

- [26] Łukosz, M., Hejmanowski, R., and Witkowski, W. (2022) Analysis of the Velocity Changes of the Jakobshavn Glacier Based on SAR Imagery. *Quaestiones Geographicae*, **41**.
- [27] Łucka, M., Hejmanowski, R., and Witkowski, W. (12, 2023) Temporal development of the displacement field of the Ponzano landslide in February 2017. *Bulletin of Geography. Socio-economic Series*, **62**, 137–151.
- [28] Łucka, M. (2025) Investigation of machine learning algorithms to determine glaciers displacements. *Remote Sensing Applications: Society and Environment*, **37**, 101476.
- [29] Joughin, I., Howat, I. M., Fahnestock, M., Smith, B., Krabill, W., Alley, R. B., Stern, H., and Truffer, M. (12, 2008) Continued evolution of Jakobshavn Isbrae following its rapid speedup. *Journal of Geophysical Research: Earth Surface*, **113**, 4006.
- [30] Joughin, I., Smith, B. E., Shean, D. E., and Floricioiu, D. (2, 2014) Brief communication: Further summer speedup of jakobshavn isbræ. *Cryosphere*, **8**, 209–214.
- [31] Khazendar, A., Fenty, I. G., Carroll, D., Gardner, A., Lee, C. M., Fukumori, I., Wang, O., Zhang, H., Seroussi, H., Moller, D., Noël, B. P., van den Broeke, M. R., Dinardo, S., and Willis, J. (4, 2019) Interruption of two decades of Jakobshavn Isbrae acceleration and thinning as regional ocean cools. *Nature Geoscience*, **12**, 277–283.
- [32] Solari, L., Raspini, F., Soldato, M. D., Bianchini, S., Ciampalini, A., Ferrigno, F., Tucci, S., and Casagli, N. (2018) Satellite radar data for back-analyzing a landslide event: the Ponzano (Central Italy) case study. *Landslides*, **15**, 773–782.
- [33] Allasia, P., Baldo, M., Giordan, D., Godone, D., Wrzesniak, A., and Lollino, G. (2019) Near Real Time Monitoring Systems and Periodic Surveys Using a Multi Sensors UAV: The Case of Ponzano Landslide. *IAEG/AEG Annual Meeting Proceedings, San Francisco, California, 2018 - Volume 1*, **1**, 303–310.
- [34] Joughin, I. MEaSURES Greenland 6 and 12 day Ice Sheet Velocity Mosaics from SAR, Version 2. (2022).
- [35] Joughin, I. MEaSURES Greenland Monthly Ice Sheet Velocity Mosaics from SAR and Landsat, Version 5. (2023).
- [36] Agency, E. S. Copernicus DEM. (2019).
- [37] Chauhan, N. K. and Singh, K. (2018) A Review on Conventional Machine Learning vs Deep Learning. In *2018 International Conference on Computing, Power and Communication Technologies (GUCON)* pp. 347–352.
- [38] Prakash, N., Manconi, A., and Loew, S. (2020) Mapping Landslides on EO Data: Performance of Deep Learning Models vs. Traditional Machine Learning Models. *Remote Sensing*, **12**(3).

- [39] Liu, R., Yang, X., Xu, C., Wei, L., and Zeng, X. (2022) Comparative Study of Convolutional Neural Network and Conventional Machine Learning Methods for Landslide Susceptibility Mapping. *Remote Sensing*, **14**(2).
- [40] LeCun, Y., Bottou, L., Bengio, Y., and Haffner, P. (1998) Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, **86**, 2278–2323.
- [41] Krizhevsky, A., Sutskever, I., and Hinton, G. E. (2012) ImageNet Classification with Deep Convolutional Neural Networks. *Advances in Neural Information Processing Systems*, **25**.
- [42] Simonyan, K. and Zisserman, A. (9, 2014) Very Deep Convolutional Networks for Large-Scale Image Recognition. *3rd International Conference on Learning Representations, ICLR 2015 - Conference Track Proceedings*,.
- [43] Wegmüller, U., Werner, C., Strozzi, T., and Wiessman, A. Automated and Precise Image Registration Procedures pp. 37–49 (2002).
- [44] Amitrano, D., Guida, R., Martino, G. D., and Iodice, A. (6, 2019) Glacier Monitoring Using Frequency Domain Offset Tracking Applied to Sentinel-1 Images: A Product Performance Comparison. *Remote Sensing*, **11**, 1322.

Spis rysunków

4.1	Lokalizacja obszarów badawczych: (A) lodowce grenlandzkie i (B) osuwisko Ponzano na podkładzie satelitarnym.	16
5.1	Schemat przetwarzania i analizy danych na potrzeby oceny użyteczności danych ICEYE. . .	19
5.2	Schemat postępowania w celu wyznaczenia przemieszczeń poziomych z wykorzystaniem modelu ML.	22
6.1	Rozkład przemieszczeń w kierunkach zasięgu i azymutu oraz maksymalne prędkości uzyskane przy użyciu obrazów radarowych z satelitów ICEYE i S-1.	26
6.2	Wykresy korelacji dla wybranych części lodowca.	27
6.3	Prędkości wzdłuż profilu lodowca z danych S-1 i ICEYE.	28
6.4	Macierz korelacji dla prędkości z obu sensorów i produktu GrIMP.	29
6.5	Obraz amplitudy dla sensora ICEYE (a) oraz S-1 (b) dla zdjęć z dnia 09.01.2021 r.	30
6.6	Prędkości dla zimy 2017 uzyskane z krótkich (a) i długich (c) baz czasowych wraz z wykresami korelacjami (b, d) odniesionymi do bazy GrIMP.	31
6.7	Prędkości dla lata 2017 uzyskane z krótkich (a) i długich (c) baz czasowych raz z wykresami korelacjami (b,d) odniesionymi do bazy GrIMP.	32
6.8	Wartości przemieszczenia obliczone w okresie 06/02/2017-18/02/2017 na podstawie obrazów S-1.	33
6.9	Rozmiar okna poszukiwawczego, a jakość wyników.	34
6.10	Mapy przemieszczeń na kierunku zasięgu radaru w zależności od rozmiaru okna poszukiwawczego.	35
6.11	Mapy przemieszczeń na kierunku azymutalnym w zależności od rozmiaru okna poszukiwawczego.	36
6.12	Wyniki dla testowego zestawu danych nr 1: (A) kierunek przesunięcia oszacowany przez CNN, (B) maksymalne prawdopodobieństwo z modelu ML, (C) wykryte przesunięcie wzdłuż osi X, (D) wykryte przesunięcie wzdłuż osi Y.	37
6.13	Wyniki dla testowego zestawu danych nr 2: (A) kierunek przesunięcia oszacowany przez CNN, (B) maksymalne prawdopodobieństwo z modelu ML, (C) wykryte przesunięcie wzdłuż osi X, (D) wykryte przesunięcie wzdłuż osi Y.	38
6.14	Wyniki obliczeń opartych na CNN dla lodowca Dagaard-Jensen dla 3 okresów: (A,C,E) mapy wektorowe kierunku ruchu lodowca i (B,D,F) średnie prędkości [m/dzień].	40

6.15	Prędkości lodowca Dagaard-Jensen obliczone przez algorytm OT (A-C), różnice między prędkościami OT i CNN (D-F) oraz histogramy tych różnic (G-I).	41
------	---	----

Spis tabel

4.1	Wykaz wykorzystanych zobrazowań radarowych.	17
5.1	Parametry wykorzystane do obliczeń metodą OT w artykule nr 1.	18
5.2	Parametry wykorzystane do obliczeń metodą OT w artykule nr 2.	20

Spis załączników

Załącznik 1. Artykuł: "Evaluation of ICEYE microsatellites sensor for surface motion detection — Jakobshavn glacier case study", Łukosz M., Hejmanowski R., Witkowski W. (2021), *Energies*, vol. 14 iss. 12 art. no. 3424, pp. 1–13, DOI: 10.3390/en14123424

Załącznik 2. Artykuł: "Analysis of the velocity changes of the Jakobshavn Glacier based on SAR imagery", Łukosz M., Hejmanowski R., Witkowski W. (2022), *Quaestiones Geographicae*, vol. 41 iss. 1, s. 93–105. DOI: 10.2478/quageo-2022-0007

Załącznik 3. Artykuł: Temporal development of the displacement field of the Ponzano landslide in February 2017", Łucka M.", Hejmanowski R., Witkowski W. (2023), *Bulletin of Geography. Socio-Economic Series*, no. 62, s. 137–151, DOI: 10.12775/bgss-2023-0039

Załącznik 4. Artykuł: "Investigation of machine learning algorithms to determine glaciers displacements", Łucka M. (2025), *Remote Sensing Applications: Society and Environment*, vol. 37, no. 101476, DOI: 10.1016/j.rsase.2025.101476

Załącznik 5. Skrypty oraz przykładowe dane powstałe w wyniku prac nad Zał. 4.

Article

Evaluation of ICEYE Microsatellites Sensor for Surface Motion Detection—Jakobshavn Glacier Case Study

Magdalena A. Łukosz , Ryszard Hejmanowski and Wojciech T. Witkowski 

Faculty of Mining Surveying and Environmental Engineering, AGH University of Science and Technology, 30-059 Cracow, Poland; hejman@agh.edu.pl (R.H.); wwitkow@agh.edu.pl (W.T.W.)

* Correspondence: lukosz@agh.edu.pl

Abstract: The marine-terminating glaciers are one of the biggest contributors to global sea-level rise. Research on this aspect of the effects of global climate change is developing nowadays in several directions. One of them is monitoring of glaciers movements, especially with satellite data. In addition to well-known analyzes based on radar data from available satellites, the possibility of studying glacier displacements from new sensors, the so-called microsatellites need to be studied. The main purpose of research was evaluation of the possibility of applying new high-resolution ICEYE radar data to observe glacier motion. Stripmap High mode were used to obtain velocities for the Jakobshavn glacier with an Offset-Tracking method. Obtained results were compared with displacements obtained from the Sentinel-1 data. The comparative analysis was performed on displacements in range and azimuth directions and for maximum velocity values. Moreover, correlation plots showed that in different parts of glaciers, a comparison of obtained velocities delivers different correlation coefficients (R^2) in a range from 0.52 to 0.97. The analysis showed that the scale of movements is similar from both sensors. However, Sentinel-1 data present underestimation of velocities comparing to ICEYE data. The biggest deviations between results were observed around the maximum velocities, near the Kangia Ice Fjord Bay. In the analysis the amplitude information was used as well. This research presents that data from the ICEYE microsatellites can be successfully used for monitoring glacial areas and it allows for more precise observations of displacement velocity field.

Keywords: marine-terminating glacier; Jakobshavn glacier; Offset-Tracking; ICEYE microsatellites; glacier surface velocity



Citation: Łukosz, M.A.; Hejmanowski, R.; Witkowski, W.T. Evaluation of ICEYE Microsatellites Sensor for Surface Motion Detection—Jakobshavn Glacier Case Study. *Energies* **2021**, *14*, 3424. <https://doi.org/10.3390/en14123424>

Academic Editor: Gleb Kraev

Received: 18 May 2021

Accepted: 8 June 2021

Published: 10 June 2021

Publisher's Note: MDPI stays neutral with regard to jurisdictional claims in published maps and institutional affiliations.



Copyright: © 2021 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

1. Introduction

Observing the ice-sheet all over the world is recently a topic of increasing importance, especially in the face of a constantly warming climate. Faster decreasing of ice masses in polar regions leads to sea-level rise [1]. Moreover, rapid detachment of the large parts of mountain glaciers causes a direct threat to human safety. Melting of ice cover and glaciers in Greenland is one of the main contributors to global sea-level rise in the world. Due to that fact, it is essential to monitor and get to know better this phenomenon. What is more, probably in perspective of few decades, the melting process will intensify [2]. Observing such movements and analysis of their dynamics changes over the years, provide us information that is necessary for a better understanding of the phenomenon that occurs in these areas [3]. Such knowledge allows better estimation of the pace of glaciers melting, the results of this process, and determining the causes of an increase in the speed of glacier motions [4].

Monitoring of glacier regions has been the subject of research for scientists from different disciplines for many years. At the beginning in-situ measurements were the only way to monitor glacial areas. However more secure methods of the monitoring were developed such as a photogrammetric survey [5]. The development of remote sensing techniques made it possible to observe these areas in a more accurate way also from a

space. Optical imagery has found its application in monitoring changes in the position of the glacier fronts [6], as well as in determining the speed of their movement. For these purposes, the feature tracking method was developed [7,8]. It allows for determining the speed of chosen area by analyzing the changes of the positions of the characteristic objects on a series of images [9]. Further technological development and the appearance of high-resolution multispectral images increased the accuracy of observations [10]. An important aspect in studying glaciers is determining the thickness of the glacial cover, as well as its changes over time. For this reason, to determine the vertical changes in glacial areas are used such methods like altimetry [11] and radar interferometry, which allows the creation of high-quality digital terrain models [12–17].

However, the advent of satellite radar imagery made it possible to start monitoring glaciers with greater precision and regardless of the current weather conditions. The differential interferometry technique (DInSAR), which is applied in many world's regions, allows determination of displacement with high accuracy, but it has some limitations. Changes that appear in areas of snow cover or mountain glaciers are characterized by the relatively high speed of daily changes, which causes a significant decrease in signal coherence in these areas [18]. For this reason, DInSAR is not always the appropriate method to obtain reliable results, despite satisfactory results in some areas [19,20]. The alternative method for determining displacements in the glacial regions is an Offset-Tracking (OT) technique, that uses information about the intensity of reflected signal [21–24]. This technique has found wide application not only in glacial regions but also in mapping other rapidly changing areas like earthquakes [25], volcanoes [26] or even mining areas [27]. This technology is usually used to determine displacements in range and azimuth direction. Other researchers started to determine vertical displacements with the use of data from different orbits or combining offset tracking method with differential interferometry [28,29]. The combination of these methods makes it possible to determine a complete velocity vector in the area where the intensity of movements is very diverse [30]. These studies are particularly important because they allow better estimation of changes in the balance of glacial masses [31]. Furthermore, it is possible to assess changes in the thickness of ice cover and estimate the contribution of individual glaciers to sea-level rise, especially considering independent altitude or meteorological data. Accurate analysis of velocities obtained from offset tracking technique improved possibilities of analyzing accelerations and deformations in glacial areas, which can lead to interruption of their surface [32]. Due to that fact, detecting spots where fissures can show up and monitoring the intensity of the calving process is possible [33]. The offset tracking method has many applications in both mountain glaciers [34–36] and polar regions [37–39]. It allows for almost real-time mapping of entire regions, such as Greenland [40] or Antarctica [41]. Moreover, usage of radar data improved investigation of such problems like ice classifications [42] or assessment of the grounding line position [43–45]. Thanks to that it is possible to show the impact of e.g., increase of average air temperature on glacier's terminus retreat [46]. Other researchers focused on a problem connected with superglacial lakes drainage and its influence on changes in glaciers speeds [47,48], or usage of SAR data for better understanding the surge process [49].

Despite there are plenty of researches using the offset tracking method, its precision is usually determined as $1/10$ – $1/30$ of the pixel size of used SAR images [50]. An increase in data resolution can improve the accuracy of detected movements and analysis of short and dynamic changes such as calving events. What is more, in the case of marine-terminating glaciers, smaller terrain pixel allows more precise determination of terminus position. Because of it, areas of floating ice where the waving of water causes vertical movements can be excluded from the analysis. This research aim is to check the possibilities of using high-resolution radar images from ICEYE microsatellites to observe glaciers. Comparative analyses were performed with the use of Sentinel-1 data. Publicly available data from the Sentinel-1 satellites provide data with a resolution nearly four times lower than that of the ICEYE microsatellites. ICEYE mission started in January 2018 and delivers images with a

resolution up to 0.25 m. So far new data from microsatellites has not been analyzed in terms of the possibility of using their potential for applications in glacial regions. This article presents a comparison of the results obtained from the Sentinel-1 and ICEYE mission. It shows the advantages and disadvantages of both data sources in the analysis of glaciers velocities on selected example.

2. Materials and Methods

2.1. Study Area

The research was carried out for the Jakobshavn glacier located in the western part of Greenland (Figure 1). So far it was one of the fastest moving glaciers in the world. Its record speed reached 46 m/day in 2012–2014 [51]. The glacier covers an area of 110,000 km², its length is about 65 km, and the estimated thickness reaches 2 km. Because of its record speeds that vary over the years, the Jakobshavn glacier became the object of diverse research. Already in the 90s of the twentieth century, using the possibilities of satellite imagery, the changes of this glacier over 30 years were observed [52]. This research showed that the retreat of glacier terminus is slowing down. There also have been significant increases in calving rate during periods of higher temperatures. Moreover, the influence of ocean temperature changes and tides on velocities and glacier thickness was investigated [53,54]. The influence of ice melange on the position of the glacier front and its stability was also analyzed [55].




Figure 1. Location of the study area—Jakobshavn Glacier (A) in Greenland (B) with testing areas and profile).

2.2. Satellite Mission Overview

In this research, new high-resolution radar images from ICEYE satellites were used. They are included in the microscale due to the small size of the sensors. Their weight reaches approx. 85 kg. Currently, the constellation consists of 10 satellites X1–X10 [56]. These satellites work in an X-band at a frequency of 9.65 GHz with left and right look directions. ICEYE offers products acquired in two modes: Spotlight (High) and Stripmap (High). The highest accuracy can be obtained for images collected in Spotlight High mode where pixel size reaches the value of 0.25 m. Scenes cover an area of 25 km² (5 km × 5 km). The ICEYE sensors are imaging only in vertical polarization (VV) and deliver images with only amplitude information (Ground Range Detected—GRD) or amplitude and phase information (Single Look Complex—SLC). Due to the extensive research area, Stripmap

High products were used. This mode is imaging in strips of $30\text{ km} \times 50\text{ km}$ (approx. 1500 km^2) with a resolution of $0.5\text{ m} \times 3\text{ m}$. Due to the kind of applied method, GRD products with a square field pixel were used, ultimately achieving a spatial resolution of $2.5\text{ m} \times 2.5\text{ m}$.

The results for the Jakobshavn glacier calculated based on ICEYE products were compared with the result from the Sentinel-1 satellites. The Sentinel-1 mission consists of 2 satellites imaging in C-band at a 5.4 GHz frequency. The mass of 1 satellite is about 945 kg (10 times more than the ICEYE satellite). Orbiting the Earth in tandem (Sentinel-1A and Sentinel-1B), they can deliver images every 6 days. In research were used images acquired in the Interferometric Wide (IW) mode. Data are collected in passes with the width of 250 km and with the resolution reaching in range and azimuth directions: from $2.7\text{ m} \times 22\text{ m}$ to $3.5\text{ m} \times 22\text{ m}$. SAR images are acquired in two kinds of polarization: HH and HV. For purposes of this research horizontal polarization was used. Data from the Sentinel-1 satellites are available in few formats but for velocities calculation, products from level-1 (GRD) were used. These images have pixel size $10\text{ m} \times 10\text{ m}$. In the case of ICEYE satellites, the pixel size of images was 4 times smaller than for Sentinel-1 products.

2.3. Data and Method

For purposes of this research images for the Jakobshavn glacier from 5 and 9 January 2021 for the ICEYE mission and from 3 and 9 January 2021 for the Sentinel-1 mission have been used (Table 1).

Table 1. Specification of the products.

Date	Sensor	Acquisition Mode	Incident Angle [°]	Heading [°]	Pixel Spacing	Swath Width	Polarization	Orbit Direction
3 January	S-1A	Interferometric Wide	30.3–45.6	203.7	$10 \times 10\text{ m}$	250 km	HH	desc
5 January	X4	Stripmap High	26.9–30.1	196.5	$2.5 \times 2.5\text{ m}$	30 km	VV	desc
9 January	S-1B	Interferometric Wide	30.3–45.6	203.2	$10 \times 10\text{ m}$	250 km	HH	desc
9 January	X7	Stripmap High	18.0–22.4	198.4	$2.5 \times 2.5\text{ m}$	30 km	VV	desc

The displacements of the Jakobshavn glacier were calculated with an Offset-Tracking method. The preparation of data was different for both sensor types (Figure 2). In the case of the Sentinel-1 data, in the first step precise orbits were attached to each SAR image. The ICEYE products contain this information and due to that, in first stage speckle filtering was applied. This step is required due to the fact, that SAR images have inherent like “salt and pepper” texturing called speckles. It degrade the quality of the image and make interpretation of features more difficult. Spatial filtering reduce significant speckle noise. In analysis the Lee-Sigma filter was used as the best compared to other filters [57]. An alternative option is using multilooking processing to speckle noise reduction [58], but in this case, the image resolution is changed as a result of aggregation of pixel in groups. The aim of this research was to check the effectiveness of ICEYE products also resulting from high resolution images, therefore this solution has not been tested.

Further calculation steps were similar for both sensors. For image coregistration, Copernicus Digital Elevation Model with a 30 m resolution was used. Then, on image pairs, groups of pixels with corresponding intensities of reflection were searched. In this process, the image is searched with a registration window. Its size depends on the maximum predicted velocity of the analyzed area. Corresponding points called Ground Control Points (GCP) are searched for in a given area. Afterward, the distance between these points is calculated and then it is converted into the velocity of the object. For both sensors, the calculation parameters were selected (Table 2) so that the results were of the same resolution in a 100 m by 100 m grid. In the last stage, the obtained results were geo-referenced to perform comparative analyzes in one coherent reference system. Characteristic glacier areas

were selected to create correlation plots from results obtained from ICEYE and Sentinel-1 data. Due to different time interval of analysis from ICEYE and Sentinel-1, the shift in range and azimuth direction was converted into the velocity values. This allowed to compare the results from both sensors despite differences in acquisitions dates. The correlation coefficients were calculated for movements in range and azimuth directions, and maximum velocities. The changes along the glacier profile are also presented. To assess changes in the bay area, the amplitude images showing terminus position and snow-ice cover were used.




Figure 2. Data processing for ICEYE and Sentinel-1 missions.

Table 2. Parameters selected for calculations using the offset-tracking technique.

Parameter	ICEYE	Sentinel-1
Max velocity [m/day]	50	50
Registration window width [pxl]	128	128
Registration window height [pxl]	128	128
Grid azimuth spacing [pxl]	40	10
Grid range spacing [pxl]	40	10

3. Results

The obtained results allowed us to determine the displacements in the Jakobshavn glacier area, illustrating the pace of changes at the beginning of January 2021. The calculation period for the Sentinel-1 mission was 6 days and for ICEYE data—4 days. For this reason, analyses were performed on velocities in range and azimuth directions and maximum velocities in m/day (Figure 3).

Data from the ICEYE microsatellite show positive displacements in the range direction in snow cover surrounding the Jakobshavn Glacier. For Sentinel-1 data values in this region have opposite signs. In the area of main glacier flow, the movement pattern is similar on both results with negative values suggesting displacement in Kangia Ice Fjord Bay direction (Figure 3). In the case of movements in the azimuth direction, both sensors show a clear separation of the positive value from the negative value. The displacement distribution in the bay area is also different.




Figure 3. Distribution of displacements in range and azimuth directions and maximum velocities obtained using radar images from the ICEYE and Sentinel-1 sensors.

The distribution of maximum velocities is comparable for both sensors, especially in parts located deeper in the land. The differences in the results are increasing with approaching the terminus and the bay. Both velocities obtained from Sentinel-1 and ICEYE data show an increase in speed in the bay direction. Despite the similar spatial distribution of observed movements, there are differences in the bay area. The maximum velocity from high-resolution ICEYE data reaches 41 m/day. For Sentinel-1 data, maximum velocity reaches the values of 36 m/day in a similar location.

The calculated velocities for both sensors were compared on a correlation plots in 4 different testing areas (Figure 4). For analysis purposes, the regions of the diverse dynamics were selected. The first testing area is in the inland part of the glacial tongue with relatively slow speeds (area 1). The next field is in the area of bigger displacements values (area 2). The next regions are part of the glacier with higher intensity of movements (area 3) and surrounding of the terminus position (area 4). The sizes of the testing areas were selected to cover only the area of the glacial tongue, without its surroundings. Due to the low velocities in the tail of the glacier and its widening in this region, the 1st area is the largest. Fields 2 and 3 have a similar size. Area 4 has the smallest size so that the speeds compared with each other are located only in the glacier front, where the movements reach

their maximum values. For selected areas, correlation plots were defined for the range and azimuth movements as well as for the maximum values. In addition, along the entire glacier, a profile was selected to show speed changes obtained from Sentinel-1 and ICEYE data in the whole area.




Figure 4. Areas where detailed comparative analyzes were applied and a field profile. The map shows the maximum velocity of glacier movement obtained based on the ICEYE satellite.

In selected areas, point grids were generated and information about velocities from both sensors was extracted. The values are presented in correlation plots for each of the analyzed regions (Figure 5). The obtained correlation coefficients (R^2) were in the range from 0.52 to 0.97. For all testing areas, the highest values were obtained for displacements in the azimuth direction. Excluding the area of the glacier terminus, R^2 for this component was in the range 0.96–0.97. In the case of displacements in range direction, coefficients reached lower values in a wide range from 0.52 to 0.93. Area 3 is the most consistent in the results obtained from both sensors. The correlation coefficient for the maximum velocities was 0.93. Also in this area, data from both ICEYE and Sentinel-1 provided results with almost the same values, hence the fitted trend line is very close to the $y = x$ function. The biggest differences in calculated velocities were obtained in area 4—the area of the terminus position. The correlation coefficient in this area is 0.71 but there are significant deviations between the results from both sensors are visible. The plot show the underestimation of the speed values in Sentinel-1 data comparing to ICEYE results. The results in areas 1 and 2 are quite similar. These regions reflect slower parts of a glacier. In the case of the azimuth component, the R^2 reaches a value of 0.96. A significantly lower correlation is visible on graphs for the range component. The correlation coefficient is in the range from 0.52 to 0.56.




Figure 5. Correlation plots for selected parts of the glacier for the area in the interior of the glacier (**area 1**), in area of higher velocities (**area 2**), in area of high-intensity movements (**area 3**), in the area of maximum values near the terminus (**area 4**).

In the last stage of the analysis, a profile was drawn along the entire glacier through its central part. Along the profile, information was collected on the velocities measured by both sensors depending on the distance from the glacier front (Figure 6). For both sensors, the maximum velocities are achieved just beyond the front of the glacier. The process of

glacier movement slows down with the distance from the terminus. Both profiles agree to the value and nature of the phenomenon. In some parts of the Jakobshavn glacier, an underestimation of velocity calculated from Sentinel-1 data is visible. The most dynamic changes are in the area where a glacier flows to the bay. The biggest deviations between results from both sensors are observed in this region. The differences are at the level of a few m/day.




Figure 6. Velocities along the glacier profile from Sentinel-1 and ICEYE data.

4. Discussion

The use of higher resolution data from the ICEYE microsatellites showed higher velocities in the glacier front region with a difference of +5 m/day (14%) compared to the results from the Sentinel-1 data. Due to difference in pixel size of the Sentinel-1 and ICEYE data, it can be concluded that the obtained differences in observations are significant and show higher values of movements observed with the use of high-resolution ICEYE data. This may result from the OT method itself, which, by aggregating a group of pixels, assigns them averaged values of movements. A higher resolution of the ICEYE data allows the detection of changes in smaller areas compared to the Sentinel-1 satellite. This is also visible in greater diversification of the pattern of movements visible in the displacement distributions. The results from the Sentinel-1 satellite data are smoother than those from the ICEYE data (Figure 4).

The analyzes performed on the profile data show that the difference in the observed velocities does not depend on the scale of the phenomenon, except the Kangia Ice Fjord Bay area. The differences in this area may occur due to floating snow-ice cover in the bay. This cover is clearly visible in the photos presenting the amplitude values (Figure 7). In the case of the Sentinel-1 products, there is no visible cut-off of the glacial tongue from the snow-ice cover floating in the waters of the bay. On the product from the ICEYE microsatellite, the terminus can be clearly distinguished from the waters in the bay with a small part of snow-ice masses. These parts of floating materials are registered in the calculation process as smaller movements in the front of the glacier. In addition, the images from 9 January show large variations in the Kangia Bay area despite the data collection on the same day. This is due to the different polarization of both sensors. In case of Sentinel-1 it is horizontal polarization (HH) in relation to ICEYE product with vertical polarization (VV) of radar signal.




Figure 7. Amplitude images from radar data acquired on 5 and 9 January 2021 by the ICEYE satellite and 3 and 9 January 2021 by the Sentinel-1 satellite.

A higher resolution of the ICEYE images allows a more precise determination of the glacier border or the location of the fissures. It is especially important in terms of the displacement analysis, to distinguish the part of the glacier which is located on stable land from floating sea-ice. In both images, this border in the central part of the glacier is visible because of the big width of the fissure between both parts (Figure 7). The SAR images from ICEYE make it possible to determine this border in a more accurate way in the side parts of the glacier.

5. Conclusions

Comparative research on the movement of the Jakobshavn glacier carried out based on the offset tracking method and images from the Sentinel-1 and ICEYE satellites allowed for an unequivocal determination of the glacier's speed throughout the entire observation range. As research shows, a higher resolution of ICEYE products compared to S-1 allows more precise identification of glacier details, especially in the terminus area. Imaging of the floating ice on S-1 is impossible. Thanks to the higher resolution, detection of velocities in different parts of the glaciers based on ICEYE data gives slightly higher values comparing to S-1. This can be an effect of an averaging pixels with larger areas in S-1 data. It can be clearly seen in the front of the glacier. These differences reach values approx. 14% of Sentinel-1 velocity. The researches carried out so far derived information about movements to 46 m/day [51]. In selected for this research period, the maximum velocity was about 36 m/d for S-1 data and 41 m/d for ICEYE data. In the presented research, the scale of these speeds was confirmed by analyzing the images of the ICEYE satellite, but the results show that the Jakobshavn glacier is slightly slowing down. Such promising results allow the

planning of further research on the possibilities of glacier displacement detection based on ICEYE microsatellites, especially about the accuracy of determining the displacement and velocity vectors. The use of new sensors from microsatellites opens up new possibilities in the prediction and future trends in the problem of glacier calving. Thanks to the use of such data, it is possible to better observe changes taking place in the Arctic regions. More accurate forecasting models can provide information on the rate of change associated with glaciers calving and thus could help to reduce the obnoxious effects of climate change and global warming.

Author Contributions: Conceptualization, R.H., W.T.W. and M.A.L.; methodology and software, W.T.W. and M.A.L.; validation, M.A.L.; formal analysis, investigation, W.T.W. and M.A.L.; resources and data curation, M.A.L.; writing—original draft preparation, W.T.W. and M.A.L.; writing—review and editing, R.H., W.T.W. and M.A.L.; visualization, W.T.W. and M.A.L.; supervision, R.H. and W.T.W.; project administration, W.T.W.; funding acquisition, R.H., W.T.W. and M.A.L. All authors have read and agreed to the published version of the manuscript.

Funding: The ICEYE data were provided by ESA, ICEYE Project no. 64675 “Possibilities of Using ICEYE Microsatellites to Estimate Glacier Surface Motion”. The research project was supported by the program “Excellence Initiative—Research University” for the AGH University of Science and Technology.

Acknowledgments: The authors acknowledge the European Space Agency (ESA) for providing Sentinel-1 and ICEYE radar satellite images. Data from Sentinel-1 are freely and fully accessible to all users at the following website: <https://scihub.copernicus.eu/> (accessed on 9 June 2021).

Conflicts of Interest: The authors declare no conflict of interest. The funders had no role in the design of the study; in the collection, analyses, or interpretation of data; in the writing of the manuscript, or in the decision to publish the results.

References

- Huss, M.; Hock, R. A new model for global glacier change and sea-level rise. *Front. Earth Sci.* **2015**, *3*, 1–22. [\[CrossRef\]](#)
- Goelzer, H.; Nowicki, S.; Payne, A.; Larour, E.; Seroussi, H.; Lipscomb, W.H.; Gregory, J.; Abe-Ouchi, A.; Shepherd, A.; Simon, E.; et al. The future sea-level contribution of the Greenland ice sheet: A multi-model ensemble study of ISMIP6. *Cryosphere* **2020**, *14*, 3071–3096. [\[CrossRef\]](#)
- Lemos, A.; Shepherd, A.; McMillan, M.; Hogg, A.E.; Hatton, E.; Joughin, I. Ice velocity of Jakobshavn Isbræ, Petermann Glacier, Nioghalvfjærdsfjorden, and Zachariæ Isstrøm, 2015–2017, from Sentinel 1-a/b SAR imagery. *Cryosphere* **2018**, *12*, 2087–2097. [\[CrossRef\]](#)
- Rignot, E.; Velicogna, I.; van den Broeke, M.R.; Monaghan, A.; Lenaerts, J.T.M. Acceleration of the contribution of the Greenland and Antarctic ice sheets to sea level rise. *Geophys. Res. Lett.* **2011**, *38*. [\[CrossRef\]](#)
- Lewńska, P.; Głowacki, O.; Moskalik, M.; Smith, W.A.P. Evaluation of structure-from-motion for analysis of small-scale glacier dynamics. *Meas. J. Int. Meas. Confed.* **2021**, *168*, 108327. [\[CrossRef\]](#)
- McNabb, R.W.; Hock, R. Alaska tidewater glacier terminus positions, 1948–2012. *J. Geophys. Res. Earth Surf.* **2014**, *119*, 153–167. [\[CrossRef\]](#)
- Huang, L.; Li, Z. Comparison of SAR and optical data in deriving glacier velocity with feature tracking. *Int. J. Remote Sens.* **2011**, *32*, 2681–2698. [\[CrossRef\]](#)
- Liu, T.; Niu, M.; Yang, Y. Ice Velocity Variations of the Polar Record Glacier (East Antarctica) Using a Rotation-Invariant Feature-Tracking Approach. *Remote Sens.* **2017**, *10*, 42. [\[CrossRef\]](#)
- Van Wychen, W.; Davis, J.; Copland, L.; Burgess, D.O.; Gray, L.; Sharp, M.; Dowdeswell, J.A.; Benham, T.J. Variability in ice motion and dynamic discharge from Devon Ice Cap, Nunavut, Canada. *J. Glaciol.* **2017**, *63*, 436–449. [\[CrossRef\]](#)
- Fahnestock, M.; Scambos, T.; Moon, T.; Gardner, A.; Haran, T.; Klinger, M. Rapid large-area mapping of ice flow using Landsat 8. *Remote Sens. Environ.* **2016**, *185*, 84–94. [\[CrossRef\]](#)
- Krieger, L.; Strößenreuther, U.; Helm, V.; Floricioiu, D.; Horwath, M. Synergistic use of single-pass interferometry and radar altimetry to measure mass loss of NEGIS outlet glaciers between 2011 and 2014. *Remote Sens.* **2020**, *12*, 996. [\[CrossRef\]](#)
- Liu, L.; Jiang, L.; Jiang, H.; Wang, H.; Ma, N.; Xu, H. Accelerated glacier mass loss (2011–2016) over the Puruogangri ice field in the inner Tibetan Plateau revealed by bistatic InSAR measurements. *Remote Sens. Environ.* **2019**, *231*, 111241. [\[CrossRef\]](#)
- Xinshuang, W.; Lingling, L.; Xiaoliang, S.; Xitao, H.; Wei, G. A high precision dem extraction method based on insar data. *ISPRS Ann. Photogramm. Remote Sens. Spatial Inf. Sci.* **2018**. [\[CrossRef\]](#)
- Sefercik, U.; Soergel, U. Comparison of High Resolution InSAR and Optical DEMs. In Proceedings of the EARSel Joint SIG Workshop, Ghent, Belgium, 22–24 September 2010.

15. Letsios, V.; Faraslis, I.; Stathakis, D. InSAR DSM using Sentinel 1 and spatial data creation. In Proceedings of the AGILE 2019, Limassol, Cyprus, 17–20 June 2019.
16. Jacobsen, K. DEM generation from satellite data. In Proceedings of the 23rd EARSel Symposium on Remote Sensing in Transition, Ghent, Belgium, 2–5 June 2003.
17. Maciuk, K.; Apollo, M.; Mostowska, J.; Lepeška, T.; Poklar, M.; Noszczyk, T.; Kroh, P.; Krawczyk, A.; Borowski, Ł.; Pavlovčič-Prešeren, P. Altitude on cartographic materials and its correction according to new measurement techniques. *Remote Sens.* **2021**, *13*, 444. [\[CrossRef\]](#)
18. Sánchez-Gámez, P.; Navarro, F.J. Glacier surface velocity retrieval using D-InSAR and offset tracking techniques applied to ascending and descending passes of sentinel-1 data for southern ellesmere ice caps, Canadian Arctic. *Remote Sens.* **2017**, *9*, 442. [\[CrossRef\]](#)
19. Nela; Bandyopadhyay; Singh; Glazovsky; Lavrentiev; Kromova; Arigony-Neto Glacier Flow Dynamics of the Severnaya Zemlya Archipelago in Russian High Arctic Using the Differential SAR Interferometry (DInSAR) Technique. *Water* **2019**, *11*, 2466. [\[CrossRef\]](#)
20. Villarroel, C.; Tamburini Beliveau, G.; Forte, A.; Monserrat, O.; Morvillo, M. DInSAR for a Regional Inventory of Active Rock Glaciers in the Dry Andes Mountains of Argentina and Chile with Sentinel-1 Data. *Remote Sens.* **2018**, *10*, 1588. [\[CrossRef\]](#)
21. Strozzi, T.; Luckman, A.; Murray, T.; Wegmüller, U.; Werner, C.L. Glacier Motion Estimation Using SAR Offset-Tracking Procedures. *IEEE Trans. Geosci. Remote Sens.* **2002**, *40*, 2384. [\[CrossRef\]](#)
22. Schellenberger, T.; Dunse, T.; Kääb, A.; Kohler, J.; Reijmer, C.H. Surface speed and frontal ablation of Kronebreen and Kongsbreen, NW Svalbard, from SAR offset tracking. *Cryosphere* **2015**, *9*, 2339–2355. [\[CrossRef\]](#)
23. Liu, B.; Jiang, W.; Zhang, J.; Luo, Y.; Gong, L. Wenchuan earthquake ruptures located by offset-tracking procedure of ENVISAT ASAR amplitude images. *Earthq. Sci.* **2010**, *23*, 283–287. [\[CrossRef\]](#)
24. Zhou, J.; Li, Z.; Guo, W. Estimation and analysis of the surface velocity field of mountain glaciers in Muztag Ata using satellite SAR data. *Environ. Earth Sci.* **2014**, *71*, 3581–3592. [\[CrossRef\]](#)
25. Chae, S.H.; Lee, W.J.; Baek, W.K.; Jung, H.S. An Improvement of the Performance of SAR Offset Tracking Approach to Measure Optimal Surface Displacements. *IEEE Access* **2019**, *7*, 131627–131637. [\[CrossRef\]](#)
26. Schaefer, L.N.; Wang, T.; Escobar-Wolf, R.; Oommen, T.; Lu, Z.; Kim, J.; Lundgren, P.R.; Waite, G.P. Three-dimensional displacements of a large volcano flank movement during the May 2010 eruptions at Pacaya Volcano, Guatemala. *Geophys. Res. Lett.* **2017**, *44*, 135–142. [\[CrossRef\]](#)
27. Yang, Z.; Li, Z.; Zhu, J.; Preusse, A.; Hu, J.; Feng, G.; Yi, H.; Papst, M. An Alternative Method for Estimating 3-D Large Displacements of Mining Areas from a Single SAR Amplitude Pair Using Offset Tracking. *IEEE Trans. Geosci. Remote Sens.* **2018**, *56*, 3645–3656. [\[CrossRef\]](#)
28. Tsai, Y.L.S.; Lin, S.Y.; Kim, J.R.; Choi, Y.S. Analysis of the seasonal velocity difference of the Greenland Russell glacier using multi-sensor data. *Terr. Atmos. Ocean. Sci.* **2019**, *30*, 541–562. [\[CrossRef\]](#)
29. Gudmundsson, S.; Gudmundsson, M.T.; Björnsson, H.; Sigmundsson, F.; Rott, H.; Carstensen, J.M. Three-dimensional glacier surface motion maps at the Gjalp eruption site, Iceland, inferred from combining InSAR and other ice-displacement data. *Ann. Glaciol.* **2002**, *34*, 315–322. [\[CrossRef\]](#)
30. Joughin, I. Ice-sheet velocity mapping: A combined interferometric and speckle-tracking approach. *Ann. Glaciol.* **2002**, *34*, 195–201. [\[CrossRef\]](#)
31. Samsonov, S.; Tiampo, K.; Cassotto, R. SAR-derived flow velocity and its link to glacier surface elevation change and mass balance. *Remote Sens. Environ.* **2021**, *258*, 112343. [\[CrossRef\]](#)
32. Gomez, R.; Arigony-Neto, J.; De Santis, A.; Vijay, S.; Jaña, R.; Rivera, A. Ice dynamics of union glacier from SAR offset tracking. *Glob. Planet. Change* **2019**, *174*, 1–15. [\[CrossRef\]](#)
33. Rohner, C.; Small, D.; Henke, D.; Lüthi, M.P.; Vieli, A. Multisensor validation of tidewater glacier flow fields derived from synthetic aperture radar (SAR) intensity tracking. *Cryosphere* **2019**, *13*, 2953–2975. [\[CrossRef\]](#)
34. Fan, J.; Wang, Q.; Liu, G.; Zhang, L.; Guo, Z.; Tong, L.; Peng, J.; Yuan, W.; Zhou, W.; Yan, J.; et al. Monitoring and Analyzing Mountain Glacier Surface Movement Using SAR Data and a Terrestrial Laser Scanner: A Case Study of the Himalayas North Slope Glacier Area. *Remote Sens.* **2019**, *11*, 625. [\[CrossRef\]](#)
35. Ganyushkin, D.A.; Chistyakov, K.V.; Volkov, I.V.; Bantsev, D.V.; Kunaeva, E.P.; Terekhov, A.V. Present glaciers and their dynamics in the arid parts of the altai mountains. *Geosciences* **2017**, *7*, 117. [\[CrossRef\]](#)
36. Fallourd, R.; Vernier, F.; Yan, Y.; Trouve, E.; Bolon, P.; Nicolas, J.-M.; Tupin, F.; Harant, O.; Gay, M.; Vasile, G.; et al. Alpine Glacier 3D Displacement Derived from Ascending and Descending TerraSAR-X Images on Mont-Blanc Test Site | VDE Conference Publication | IEEE Xplore. Available online: <https://ieeexplore.ieee.org/abstract/document/5758789> (accessed on 23 March 2021).
37. Lugli, A.; Vittuari, L. A polarimetric analysis of COSMO-SkyMed and RADARSAT-2 offset tracking derived velocities of David-Drygalski Glacier (Antarctica). *Appl. Geomatics* **2017**, *9*, 43–52. [\[CrossRef\]](#)
38. Strozzi, T.; Paul, F.; Wiesmann, A.; Schellenberger, T.; Kääb, A. Circum-Arctic Changes in the Flow of Glaciers and Ice Caps from Satellite SAR Data between the 1990s and 2017. *Remote Sens.* **2017**, *9*, 947. [\[CrossRef\]](#)

39. Boncori, J.P.M.; Andersen, M.L.; Dall, J.; Kusk, A.; Kamstra, M.; Andersen, S.B.; Bechor, N.; Bevan, S.; Bignami, C.; Gourmelen, N.; et al. Intercomparison and Validation of SAR-Based Ice Velocity Measurement Techniques within the Greenland Ice Sheet CCI Project. *Remote Sens.* **2018**, *10*, 929. [\[CrossRef\]](#)
40. Joughin, I.; Smith, B.E.; Howat, I.M.; Scambos, T.; Moon, T. Greenland flow variability from ice-sheet-wide velocity mapping. *J. Glaciol.* **2010**, *56*, 415–430. [\[CrossRef\]](#)
41. Jawak, S.D.; Kumar, S.; Luis, A.J.; Pandit, P.H.; Wankhede, S.F.; Anirudh, T.S. Seasonal Comparison of Velocity of the Eastern Tributary Glaciers, Amery Ice Shelf, Antarctica, Using SAR Offset Tracking. *ISPRS Ann. Photogramm. Remote Sens. Spat. Inf. Sci.* **2019**, *4*, 595–600. [\[CrossRef\]](#)
42. Boulze, H.; Korosov, A.; Brajard, J. Classification of sea ice types in sentinel-1 SAR data using convolutional neural networks. *Remote Sens.* **2020**, *12*, 2165. [\[CrossRef\]](#)
43. Rignot, E.; Mouginot, J.; Morlighem, M.; Seroussi, H.; Scheuchl, B. Widespread, rapid grounding line retreat of Pine Island, Thwaites, Smith, and Kohler glaciers, West Antarctica, from 1992 to 2011. *Geophys. Res. Lett.* **2014**, *41*, 3502–3509. [\[CrossRef\]](#)
44. Rignot, E. Mass balance of East Antarctic glaciers and ice shelves from satellite data. *Ann. Glaciol.* **2002**, *34*, 217–227. [\[CrossRef\]](#)
45. Brancato, V.; Rignot, E.; Milillo, P.; Morlighem, M.; Mouginot, J.; An, L.; Scheuchl, B.; Jeong, S.; Rizzoli, P.; Bueso Bello, J.L.; et al. Grounding Line Retreat of Denman Glacier, East Antarctica, Measured With COSMO-SkyMed Radar Interferometry Data. *Geophys. Res. Lett.* **2020**, *47*, e2019GL086291. [\[CrossRef\]](#)
46. Moon, T.; Joughin, I. Changes in ice front position on Greenland’s outlet glaciers from 1992 to 2007. *J. Geophys. Res.* **2008**, *113*, F02022. [\[CrossRef\]](#)
47. Heil, P.; Enderlin, E.M.; Kjeldsen, K.K.; Neckel, N.; Zeising, O.; Steinhage, D.; Helm, V.; Humbert, A. Seasonal Observations at 79 • N Glacier (Greenland) From Remote Sensing and in situ Measurements. *Front. Earth Sci.* **2020**, *1*, 142. [\[CrossRef\]](#)
48. Wendleder, A.; Friedl, P.; Mayer, C. Impacts of Climate and Supraglacial Lakes on the Surface Velocity of Baltoro Glacier from 1992 to 2017. *Remote Sens.* **2018**, *10*, 1681. [\[CrossRef\]](#)
49. Pritchard, H. Glacier surge dynamics of Sortebrae, east Greenland, from synthetic aperture radar feature tracking. *J. Geophys. Res.* **2005**, *110*, F03005. [\[CrossRef\]](#)
50. Li, G.; Lin, H.; Li, Y.; Zhang, H.; Jiang, L. Monitoring glacier flow rates dynamic of Geladandong Ice Field by SAR images Interferometry and offset tracking. *Int. Geosci. Remote Sens. Symp.* **2014**, 4022–4025. [\[CrossRef\]](#)
51. Joughin, I.; Smith, B.E.; Shean, D.E.; Floricioiu, D. Brief communication: Further summer speedup of jakobshavn isbrae. *Cryosphere* **2014**, *8*, 209–214. [\[CrossRef\]](#)
52. Sohn, H.-G.; Jezek, K.C.; van der Veen, C.J. Jakobshavn Glacier, west Greenland: 30 years of spaceborne observations. *Geophys. Res. Lett.* **1998**, *25*, 2699–2702. [\[CrossRef\]](#)
53. Holland, D.M.; Thomas, R.H.; De Young, B.; Ribergaard, M.H.; Lyberth, B. Acceleration of Jakobshavn Isbr triggered by warm subsurface ocean waters. *Nat. Geosci.* **2008**, *1*, 659–664. [\[CrossRef\]](#)
54. Khazendar, A.; Fenty, I.G.; Carroll, D.; Gardner, A.; Lee, C.M.; Fukumori, I.; Wang, O.; Zhang, H.; Seroussi, H.; Moller, D.; et al. Interruption of two decades of Jakobshavn Isbrae acceleration and thinning as regional ocean cools. *Nat. Geosci.* **2019**, *12*, 277–283. [\[CrossRef\]](#)
55. Amundson, J.M.; Fahnestock, M.; Truffer, M.; Brown, J.; Lüthi, M.P.; Motyka, R.J. Ice mélange dynamics and implications for terminus stability, Jakobshavn Isbrae, Greenland. *J. Geophys. Res.* **2010**, *115*, F01005. [\[CrossRef\]](#)
56. ICEYE. Available online: <https://www.iceye.com/sar-data/orbits> (accessed on 2 June 2021).
57. Lee, J.S.; Pottier, E. *Polarimetric Radar Imaging: From Basics to Applications*; CRC Press: Boca Raton, FL, USA, 2009; ISBN 9781420054989.
58. Small, D.; Schubert, A. Guide to ASAR Geocoding. *ESA-ESRIN Tech. Note RSL-ASAR-GC-AD* **2008**, *1*, 36.

ANALYSIS OF THE VELOCITY CHANGES OF THE JAKOBHAVN GLACIER BASED ON SAR IMAGERY

MAGDALENA ŁUKOSZ , RYSZARD HEJMANOWSKI , WOJCIECH T. WITKOWSKI 

Department of Mining Areas Protection, Geoinformatics and Mining Surveying, AGH University of Science and Technology, Cracow, Poland

Manuscript received: October 14, 2021

Revised version: February 18, 2022

ŁUKOSZ M., HEJMANOWSKI R., WITKOWSKI W. T., 2021. Analysis of the velocity changes of the Jakobshavn Glacier based on SAR imagery. *Quaestiones Geographicae* 41(1), Bogucki Wydawnictwo Naukowe, Poznań, pp. 93–105. 11 figs, 2 tables.

ABSTRACT: The study analyzes the changes in dynamics of the Jakobshavn Glacier in summer and winter in 2017 and 2021. Satellite radar observations and the available database were used for this. Moreover, the influence of the time baseline between SAR images on the quality of the results was also investigated. The velocities computed from Sentinel-1 images and the offset-tracking technique were compared with the MEaSUREs database information. The results showed that Jakobshavn Glacier accelerated in 2021 up to 39.0 m d^{-1} . However, this value may be underestimated due to the resolution of Sentinel-1 data. The results therefore confirm the acceleration of the glacier melting process, which may be a result of the observed climate changes on our planet.

KEYWORDS: marine-terminating glacier, offset-tracking, SAR imagery, glacier surface velocity, temporal changes in dynamics

Corresponding author: Magdalena Łukosz, lukosz@agh.edu.pl

Introduction

Melting of glaciers and global ice mass loss are well-known problems nowadays due to plenty of existing studies focusing on the consequences of climate change (Joughin et al. 2010; Vizcaino et al. 2015, Golledge et al. 2019, Wu et al. 2020). Both processes have accelerated in recent years (Hugonnet et al. 2021). The problem of melting glaciers occurs not only in polar regions like the Arctic or Antarctic (Rignot et al. 2014, Lemos et al. 2018a, Tuckett et al. 2019, Joughin et al. 2020) but also in mountains (Zhou et al. 2014, Gatti et al. 2018, Du et al. 2019). The melting of glaciers consequently leads to an increase in

sea-level (Aschwanden et al. 2019, Golledge 2020). Greenland is a major contributor to sea-level rise and the velocity of the flow of outlet glaciers is one of the factors influencing the rate of ice mass loss (King et al. 2020). Therefore, persistent monitoring of glacier velocities and their responses to changing conditions is necessary for an accurate estimation of the mass balance.

This study is focused on the biggest and fastest glacier in Greenland, called Jakobshavn. Due to the significant velocities of ice displacement observed for many years, it became an object of interest for researchers (Sohn et al. 1998, Luckman, Murray 2005, Farness, Jezek 2008). The glacier velocity near the terminus position reached 6700

m a^{-1} in 1985 (Joughin et al. 2004). The velocity was estimated by tracking crevasse displacements on airborne imagery. Until 1992, the Jakobshavn Isbrae was slowing down. The InSAR results showed that in 1992 its maximum speed was 5700 m a^{-1} , but then it started to accelerate rapidly until 2003, reaching even 12600 m a^{-1} . It was caused by the warming of the ocean tides (Holland et al. 2008). Further studies confirmed observed phenomenon in the years 2004–2007 (Joughin et al. 2008). The long-lasting acceleration period in Jakobshavn glacier history resulted in the record velocity noted in the 2012–2013 summer periods. The maximum velocity at the terminus exceeded 17000 m a^{-1} (Joughin et al. 2014). In 2016, the glacier slowed down until 2018 (Khazendar et al. 2019). However in summer 2019, the acceleration at the level of 1500 m a^{-1} was observed (Joughin et al. 2020). New research can confirm acceleration in the dynamics of glacier movements.

Although the regular observation of glaciers is important, it may be challenging due to unfavourable weather conditions, high velocities, and sometimes hindered access to such places. Nevertheless, current easier access to satellite data allows for persistent monitoring of these regions. Especially useful are radar sensors, which acquire data regardless of weather conditions (Lee, Pottier 2009). Currently, SAR satellites are useful tools in cryosphere monitoring, as they are used for observation of displacements of ice masses, assessing grounding line position, or glacier mapping (Winsvold et al. 2018, Friedl et al. 2020, Samsonov et al. 2021). SAR data is used in a variety of techniques to estimate surface movements, including radar interferometry (InSAR) and offset-tracking methods. The main difference between those two methods is that InSAR uses information about the phase of the radar signal (Massonnet, Feigl 1998, Hanssen 2001), while the offset-tracking technique is based on intensity information (Strozzi et al. 2002). Application of the InSAR method in regions where dynamic movements of land surface occur may lead to a loss of coherence (Trouvé et al. 2005). Wherefore, the offset-tracking method is mainly used in ice-covered areas, where velocities are significant and major displacements appear in the horizontal plane. This technique is widely used to obtain glacier surface velocities (Yan et al. 2013, Strozzi

et al. 2017, Gomez et al. 2019, Fang et al. 2020, Neckel et al. 2020) but also displacement values in mining areas (Huang et al. 2016, 2020, Zhao et al. 2021) or even in the areas of landslides (Cai et al. 2017; Sun et al. 2017) or sand dunes (Mahmoud et al. 2020). The accuracy of this method is determined as $1/10$ – $1/30$ of the pixel size (Fan et al. 2019). There are also other algorithms for glacier velocity calculations. Some studies show the potential of applying optical imagery and the feature tracking method to monitor such areas, but a collection of useful optical imagery sets is challenging due to polar night or mountainous areas (Guo et al. 2013, Kääb et al. 2016). Another algorithm used in glacier monitoring is autoRIFT, which is also based on normalized cross-correlation but employs progressive window sizes (Lei et al. 2021). Another approach is dense image matching (Schubert et al. 2013). However, compared to cross-correlation techniques, it is less valuable for glaciological purposes and monitoring of large areas.

When the Sentinel-1 mission was released, SAR imagery became a popular data source for different studies, including glacier areas (Nagler et al. 2015). Data is collected at regular intervals and open access is provided. Because observations of surface movements have become easier and timelier (Torres et al. 2012), it led to launching new projects focusing on the usage of satellite data, also for glacier monitoring, such as GIMP (Greenland Ice sheet Mapping Project). Its main objective is to monitor changes in ice sheets and selected glaciers in Greenland (Joughin et al. 2010). Results are distributed by the National Snow and Ice Data Centre (NSIDC) as a part of the MEaSUREs program. This program is coordinated by NASA and its main aim is to share data about the Earth with the scientific community. The MEaSUREs database contains glacier velocities calculated based on TerraSAR-X radar images. Both, the Sentinel-1 imagery and the MEaSUREs database were used in this research.

In spite that there are some research projects collecting information about glacier movements through the years (Joughin et al. 2010), an update of databases is performed with a delay. In some areas, including the Jakobshavn glacier, the pace of velocity changes is high. Considering that glacier flow velocities affect ice mass balance, constant

monitoring of such areas is necessary. Therefore, the presented research focuses on two objectives:

- determine the dynamics in 2021 year of the Jakobshavn glacier's movements and compare the results with selected previous period;
- compare the obtained results with the available database and verify the existing algorithm.

This study shows a comparison of velocities between winter and summer in 2017 and 2021 for the Jakobshavn glacier. This analysis was conducted to deliver a new information about the current velocity of this glacier. Velocities were calculated by the offset-tracking technique using Sentinel-1 SAR acquisition and open-source SNAP (SeNtinel Application Platform) software. In order to obtain the most reliable results, velocities from 2017 were calculated for different time baselines and compared with values from the MEaSUREs database. Therefore, it was possible to assess the influence of the time baseline on the quality of the results. Assessment of current velocities of the Jakobshavn glacier may enable an analysis of its response to climate changes and deliver reliable data for glaciological society. Moreover, an interruption of the slowing-down process is a stimulus to study more carefully which factors triggered such changes, and accurate velocity monitoring is needed for these purposes.

Materials and Methods

Study area

The study area of this research is the Jakobshavn Glacier, located in the western part of Greenland (Fig. 1). Jakobshavn covers an area of about 110 000 km², its length is more than 65 km, and the thickness of the ice masses is about 2 km.

SAR data used in the study

A total of 10 SAR images were used for velocity calculations. They were registered by the Sentinel-1 (S-1) twin satellites that deliver satellite imagery every 6 days almost all over the world. The data were collected for the winter and summer periods of 2017 and 2021 (Table 1). Calculations were performed in 6 intervals with the 6-day baseline for each period and additionally 24- and 30-day baselines in 2017. To implement the offset-tracking method the Ground Range Detected (GRD) products were used with a pixel spacing of 10 × 10 m and a resolution of 20 × 22 m (ESA n.d.). The GRD products are preprocessed SAR data that has been multi-looked and projected to the ground range using an Earth ellipsoid model. Data were acquired in two descending passes: pass 127 for images from 2017 and pass 25




Fig. 1. Location of the area of interest (AOI): A) position of the Jakobshavn glacier on the Greenland map, B) precise location of the glacier near Kangia Bay.

Table 1. Description of data used in the study.

No.	Data of image acquisition	Orbit number	Time base-line [days]	Period
1	31.01.2017	127	6	Winter 2017
	06.02.2017	127		
2	31.01.2017	127	24	
	24.02.2017	127		
3	30.07.2017	127	6	August 2017
	05.08.2017	127		
4	30.07.2017	127	30	
	29.08.2017	127		
5	03.01.2021	25	6	Winter 2021
	09.01.2021	25		
6	01.08.2021	25	6	August 2021
	07.08.2021	25		

for 2021 data. The images were registered using Interferometric Wide mode (IW) with dual horizontal polarization (HH).

MEaSURES data

Acquired datasets from the MEaSURES program (Making Earth System Data Records for Use in Research Environments) consist of

displacement maps for a selected glacier in GeoTIFF format. Calculations were performed on the basis of SAR images, which were acquired by twin satellites TerraSAR-X/TanDEM-X from the German Aerospace Center (DLR). Delivered raster data have a temporal resolution of 11 days and spatial resolution of 100×100 m. They contain velocities along the x and y-axis with estimated errors for these values, as well as the resultant velocity in m a^{-1} . In this research, two datasets were used. They represent the velocities of Jakobshavn Glacier in February and August 2017 (Fig. 2). The datasets are not published continuously but are updated regularly (e.g. for 1.5 years). The current available version delivers information about glaciers' velocities until May 2021 (Joughin et al. 2021).

The spatial distribution of displacements for these periods is similar. The glacier terminus slightly retreats in the summer months and the velocities are higher. In August, the maximum velocity reaches more than 39 m d^{-1} , while during February it is about 31 m d^{-1} . The greatest velocities are near the terminus position.




Fig. 2. Velocities of the Jakobshavn Glacier from the MEaSURES database.

Processing

To obtain the velocities of a glacier, the intensity SAR data from Sentinel-1 satellites were used. The displacements of the Jakobshavn glacier were calculated with the offset-tracking method. This technique allows detecting sub-pixel offsets between two images covering the same area using normalized cross-correlation (Strozzi et al. 2002, Xu et al. 2020). Calculations were performed using open-source SNAP (Sentinel Application Platform) software, provided by the European Space Agency (ESA), for six periods using the same input parameters (Table 2).

In the first step of processing, for each Sentinel-1 image, a file containing information about precise orbits was attached. In the next step, the pairs of the SAR images were co-registered using the digital terrain model ACE30. Afterward, the offset-tracking procedure was applied. The corresponding pixels were searched in both SAR intensity images. The search area was determined by the size of the registration window, which depends on the maximum velocity which can occur in the selected region and the time interval between images. In those limited areas, corresponding points, called Ground Control Points (GCP), are searched. In a further step, distances between these points are calculated in range and azimuth direction, and therefore maximum velocities and their directions are computed. In the last step of processing in the SNAP software, the terrain correction was applied. Georeferenced displacement maps were exported into GeoTIFF format.

To carry out spatial analyses, results from S-1 images and displacement maps from the MEaSUREs database were imported into Quantum GIS (QGIS) software and converted into one coherent reference system. In the next step, a grid of points covering the majority of a glacier was created. For each point, velocity values were extracted from the MEaSUREs database as well as from long- and short-time SNAP calculations.

Table 2. Parameters for the offset-tracking procedure.

Parameters	
DTM	ACE30
Grid size	20 × 20 pxl (200 × 200 m)
Searching window	128 × 128 pxl
Max velocity	40 m d ⁻¹




Fig. 3. Workflow.

On the ground of these data, correlation plots for summer and winter 2017 were created. In the last stage of analysis, 4 profiles were created for the Jakobshavn glacier: one along the main flow and 3 perpendicular profiles. Plots enabled analysis of changes in glacier velocity between 2017 and 2021. The steps of data processing and analysis are presented in the workflow diagram (Fig. 3).

Results

The results of this research are 6 velocity maps for Jakobshavn Glacier obtained by the offset-tracking technique for February 2017, August 2017, January 2021, and August 2021 (Fig. 4). For February and August 2017, two maps for each month were created, containing velocities calculated over a short and long time interval. The obtained results differ not only in the value of the calculated speed but also in the spatial extent where it was possible to locate glacier movements.

In February 2017, two calculating intervals were tested to check the influence of time baseline on the quality of the obtained results. The velocities were calculated at 6- and 24-day intervals. For both periods, the area of detected movements also covers part of the sea-ice floating in the Kangia Bay. For a shorter time baseline, the maximum glacier speed is 31.4 m d⁻¹ and in the longer interval, it reaches 27.5 m d⁻¹. For a 24-day

period, velocities are lower in the whole area of the Jakobshavn glacier. Moreover, the continuity of results is disturbed, and more noises appear. The maximum values appear near the terminus but there is no visible cut-off between the glacier tongue and sea-ice cover.

The results of the calculations in both intervals were compared with the velocities from the MEaSUREs database. The correlation plots were

created for each pair (Fig. 5). The correlation coefficient for a long interval is 0.25 and for a 6-day period is 0.67. The correlation plot for the 24-day baseline is characterized by a large dispersion of points. A shorter calculation interval results in a significant increase in R^2 value.

For August 2017, velocities were also calculated for two intervals: 6- and 30-days (Fig. 6) and compared to the values from the MEaSUREs




Fig. 4. Velocities for winter 2017 obtained from short and long intervals.




Fig. 5. Correlation plots for winter 2017.

database (Fig. 7). A shorter baseline showed a maximum velocity of 25.0 m d^{-1} . The shape of the glacier and the spatial extent of displacements is similar to data presented in the MEaSURES database. In the map created for a longer period, a large number of noises are visible. It was also impossible to determine velocities near the glacier terminus. The maximum speed is less than 23.0 m d^{-1} . The correlation plots for summer 2017

present similar results to those from the winter (Fig. 7). The 30-day interval shows lack of correlation between velocities from the SNAP and the MEaSURES database. The correlation coefficient for 6-day calculations is equal to 0.78. For both periods summer and winter 2017, a significant increase in data quality is visible with a shorter time interval. Velocities from 6-day calculation periods show a higher correlation with values from




Fig. 6. Velocities for summer 2017 obtained from long and short calculation intervals.




Fig. 7. Correlation plots for summer 2017.

independent datasets. They also contain fewer noises and present more reliable results near the terminus and borders of a glacier. However, for both seasons, Sentinel-1 data present an underestimation of displacement values compared to TerraSAR-X/TanDEM-X results.

The MEaSURES database contains information about the velocity of selected glaciers but it is not updated regularly. To obtain information about velocity of glacier in newer period, it was

necessary to calculate displacement using only Sentinel-1 data. Tests for 2017 datasets showed that shorter intervals deliver more reliable results, so calculations in winter and summer 2021 were performed at 6-day intervals. The maximum velocities for both seasons are similar. In January, it is 38.0 m d^{-1} and in August, about 39.0 m d^{-1} (Fig. 8). However, in the map from summer, it is visible that high displacement values are located in a large part of a glacier located near Kangia




Fig. 8. Velocities of the Jakobshavn Glacier in winter and summer 2021.




Fig. 9. Location of profiles.

Bay. Moreover, data from August 2021 present another small part of moving ice cover in the west-north part of the map. In winter 2021, no significant movements were registered in this part. For both seasons, the spatial distribution of maximum velocities is similar compared to the MEaSURES database.

To describe changes in glacier dynamics, velocities along 4 profiles were compared between 2017 and 2021 (Fig. 9). One profile was selected along a line representing the flow of a glacier. 3 profiles were created transverse to the flow line: near the terminus position, in the area of the middle and low values of velocities. Profiles were created for the winter and summer months. A comparison was performed on the 2017 SNAP

results, the MEaSURES database, and velocities in 2021 obtained from the SNAP software.

Profile 1, located near the front of a glacier, shows slight acceleration of a glacier. The maximum velocity in this part of the glacier increased by about 5.0 m d^{-1} , taking into account only the results from SNAP. The 2nd profile shows that velocities calculated based on Sentinel-1 images did not change significantly. Values from the MEaSURES database present similar velocities but they are horizontally shifted compared to SNAP results. For the winter months, profile 3 shows similar changes in the glacier velocity in 2017 and 2021 (Fig. 10). The last profile was analyzed along with the main flow direction of the glacier. The mean deviation between SNAP




Fig. 10. Winter profiles presenting velocity values.

velocities from 2017 and 2021 was 2.3 m d^{-1} and between MEaSUREs database 2.5 m d^{-1} . For most of the glacier length, velocities did not change in analyzed periods. The biggest deviations are observed closer to the terminus position. The Jakobshavn glacier increased its velocity in 2021. The maximum velocity along profile 4 reaches in 2021 more than 10 meters more related to similar period in 2017.

Similar profiles were analyzed for velocities in August 2017 and 2021 (Fig. 11). In each of the 4 profiles, a speedup of the Jakobshavn glacier is visible. However, deviations between SNAP values from 2017 and 2021 are greater than in comparison with MEaSUREs velocities. In the first profile, maximum velocity has changed by

almost 20 m d^{-1} between SNAP calculations. Compared to the MEaSUREs database, the maximum velocity of the glacier increased by almost 10 m d^{-1} . Profiles 2 and 3 also show an increase in velocity values in August 2021. SNAP velocities are higher even about $8\text{--}10 \text{ m d}^{-1}$ but comparison with independent database also shows acceleration at the level of a few m d^{-1} . Profile 4, presenting changes in the velocity alongside the main flow of the glacier, shows a speedup along the entire glacier in summer 2021. In the front part of a glacier, the increase in velocity reaches even 20 m d^{-1} . Values from the MEaSUREs database from 2017 show smaller changes in velocity. However, the velocity has changed by almost 10 m d^{-1} in areas of the greatest velocities.




Fig. 11. Summer profiles presenting velocity values.

Discussion

The presented study shows that calculations using the offset-tracking technique deliver more reliable results for shorter time baselines. Velocities based on shorter intervals show a higher correlation with values from the MEaSUREs database. Fast changes in glacier structure probably resulted in the poor quality of the results from the long interval. However, even for a short time baseline, there are differences between these two sources. It probably results from the different pixel sizes of SAR images. Cross-correlation algorithm aggregates the information from lower resolution of Sentinel-1. Thus, the satellite signal is averaged over a larger area, which results in underestimating the maximum values compared to the results for TerraSAR-X data. The results also reveal an acceleration of the Jakobshavn glacier in 2021 compared to 2017. The acceleration is visible between calculations in the SNAP software, which were conducted on the same input processing parameters. The velocity change at the level of several or even a dozen meters between those two periods is significant. According to previous studies, the velocity of the Jakobshavn glacier had been decreasing until 2018 (Khazendar et al. 2019). In 2017, a slow-down period was observed (Riel et al. 2021) and even the seasonal variability of ice speed diminished (Lemos et al. 2018b), which is also visible in the presented velocity maps. In 2019, this downward trend (Joughin et al. 2020) was disturbed, but there were no more studies confirming the trend reversal. The results of this research for 2021 indicate that the Jakobshavn glacier started to accelerate again, and 2019 was probably the turning point. Moreover, in summer 2021, the calculated maximum velocity reached 39.0 m d^{-1} , which is in agreement with a prediction from 2020 (Willis et al. 2020). The expected value of ice velocity was 14.4 km a^{-1} , which corresponds to approx. 39.5 m d^{-1} . What is more, a yearly analysis of the Greenland ice sheet also confirmed that the Jakobshavn Isbræ has accelerated again between 2020 and 2021 (Mottram et al. 2021).

Conclusion

In this research, results obtained for 2017 allowed comparison of existing algorithms used in

glacier dynamics studies. Results from Sentinel-1 data present underestimation of displacement compared to the MEaSUREs database results. Furthermore, the use of open-source software and Sentinel-1 data in this research allowed confirmation of the acceleration trend for the Jakobshavn glacier. However, due to fact of low resolution of Sentinel-1 data, it should be supposed that the maximum value of the velocity in 2021 is greater than obtained result 39.0 m d^{-1} . Taking into account the possible underestimation of the results for the Sentinel-1 data, the obtained results can be important in research of glacial dynamics, as the results of climate change. It is also important to deeper analyze the possible causes of such acceleration because it can result in further thinning and melting of a glacier. In further research, the possible causes of velocity changes should be analyzed, including weather conditions such as temperature and precipitation, or sea temperature. Nonetheless, the variability of velocity changes is one of the crucial aspects in glacial changes studies.

Acknowledgements

We would like to thank the European Space Agency and the National Snow and Ice Data Center for providing us with access to radar images, as well as velocity data from the MEaSUREs database. We would also like to express our gratitude to anonymous reviewers who revised the original version of the manuscript and contributed to the improvement of its quality.

Author's contribution


Ł.M. – 70% – data preparation and processing, research methodology, analysis, preparation of the manuscript; H.R. – 10% – writing, review and editing; W.W.T. – 20% – writing, data analysis, review and editing. All authors have read and agreed to the published version of the manuscript.

References

- Aschwanden A., Fahnestock M.A., Truffer M., Brinkerhoff D.J., Hock R., Khroulev C., Mottram R., Khan A.S., 2019. Contribution of the Greenland Ice Sheet to sea level over the next millennium. *Science Advances* 5(6). DOI [10.1126/SCIADV.AAV9396](https://doi.org/10.1126/SCIADV.AAV9396).
- Cai J., Wang C., Mao X., Wang Q., 2017. An adaptive offset tracking method with SAR images for landslide displacement monitoring. *Remote Sensing* 9(8): 830.

- Du W., Liu X., Guo J., Shen Y., Li W., Chang X., 2019. Analysis of the melting glaciers in Southeast Tibet by ALOS-PAL-SAR data. *Terrestrial, Atmospheric and Oceanic Sciences* 30: 7–19.
- ESA. n.d. *Sentinel-1 SAR technical guide*. Online: <https://sentinels.copernicus.eu/web/sentinel/technical-guides/sentinel-1-sar/products-algorithms/level-1-algorithms/ground-range-detected> (accessed 11 October 2021).
- Fan J., Wang Q., Liu G., Zhang L., Guo Z., Tong X., Peng J., et al., 2019. Monitoring and analyzing mountain glacier surface movement using SAR data and a terrestrial laser scanner: A case study of the Himalayas north slope glacier area. *Remote Sensing* 11(6): 625.
- Fang L., Ye Z., Su S., Kang J., Tong X., 2020. Glacier surface motion estimation from SAR intensity images based on subpixel gradient correlation. *Sensors* 20(16): 4396.
- Farness K., Jezek K.C., 2008. *Velocity trends for Jakobshavn glacier, Greenland for the years 2000, 2004, 2005, and 2006 including procedure manuals*. Byrd Polar Research Center, The Ohio State University. Online: <https://kb.osu.edu/handle/1811/54467> (accessed 14 January 2022).
- Friedl P., Weiser F., Fluhrer A., Braun M.H., 2020. Remote sensing of glacier and ice sheet grounding lines: A review. *Earth-Science Reviews* 201: 102948.
- Gatti R.C., Dudko A., Lim A., Velichevskaya A.I., Lushchava I.V., Pivovarov A.V., Ventura S., Lumini E., Berruti A., Volkov I.V., 2018. The last 50 years of climate-induced melting of the Maliy Aktru glacier (Altai Mountains, Russia) revealed in a primary ecological succession. *Ecology and Evolution* 8(15): 7401–7420.
- Golledge N.R., 2020. Long-term projections of sea-level rise from ice sheets. *Wiley Interdisciplinary Reviews: Climate Change* 11(2): e634.
- Golledge N.R., Keller E.D., Gomez N., Naughten K.A., Bernales J., Trusel L.D., Edwards T.L., 2019. Global environmental consequences of twenty-first-century ice-sheet melt. *Nature* 566(7742): 65–72.
- Gomez R., Arigony-Neto J., De Santis A., Vijay S., Jaña R., Rivera A., 2019. Ice dynamics of union glacier from SAR offset tracking. *Global and Planetary Change* 174: 1–15.
- Guo W., Liu S., Wei J., Bao W., 2013. The 2008/09 surge of central Yulinchuan glacier, northern Tibetan Plateau, as monitored by remote sensing. *Annals of Glaciology* 54(63): 299–310.
- Hanssen R., 2001. *Radar interferometry – Data interpretation and error analysis*, 1st edn., Vol. 2. Springer Netherlands, Dordrecht. DOI 10.1007/0-306-47633-9.
- Holland D.M., Thomas R.H., De Young B., Ribergaard M.H., Lyberth B., 2008. Acceleration of Jakobshavn Isbræ triggered by warm subsurface ocean waters. *Nature Geoscience* 1(10): 659–664.
- Huang J., Bai Y., Lei S., Deng K., 2020. Time-series SBAS pixel offset tracking method for monitoring three-dimensional deformation in a mining area. *IEEE Access* 8: 118787–118798.
- Huang J., Deng K., Fan H., Yan S., 2016. An improved pixel-tracking method for monitoring mining subsidence. *Remote Sensing Letters* 7(8): 731–740. DOI 10.1080/2150704X.2016.1183177.
- Hugonnet R., McNabb R., Berthier E., Menounos B., Nuth C., Girod L., Farinotti D., Huss M., Dussaillant I., Brun F., Kääb A., 2021. Accelerated global glacier mass loss in the early twenty-first century. *Nature* 592(7856): 726–731.
- Joughin I., Abdalati W., Fahnestock M., 2004. Large fluctuations in speed on Greenland's Jakobshavn Isbræ glacier. *Nature* 432(7017): 608–610.
- Joughin I., Shean D.E., Smith B.E., Floricioiu D., 2020. A decade of variability on Jakobshavn Isbræ: Ocean temperatures pace speed through influence on mélange rigidity. *Cryosphere* 14(1): 211–227.
- Joughin I., Howat I.M., Fahnestock M., Smith B., Krabill W., Alley R.B., Stern H., Truffer M., 2008. Continued evolution of Jakobshavn Isbræ following its rapid speed-up. *Journal of Geophysical Research: Earth Surface* 113(F4): 4006.
- Joughin I., Smith B.E., Howat I.M., Scambos T., Moon T., 2010. Greenland flow variability from ice-sheet-wide velocity mapping. *Journal of Glaciology* 56(197): 415–430.
- Joughin I., Smith B.E., Shean D.E., Floricioiu D., 2014. Brief communication: Further summer speedup of Jakobshavn Isbræ. *Cryosphere* 8(1): 209–214.
- Joughin I., Howat I.M., Smith B., Scambos T., 2021. *MEaSUREs Greenland Ice Velocity: Selected Glacier Site Velocity Maps from InSAR*, Version 4. [Jakobshavn Glacier]. Boulder, Colorado USA. NASA National Snow and Ice Data Center Distributed Active Archive Center. DOI 10.5067/GQZQY2M5507Z.
- Kääb A., Winsvold S.H., Altena B., Nuth C., Nagler T., Wuite J., 2016. Glacier remote sensing using Sentinel-2. Part I: Radiometric and geometric performance, and application to ice velocity. *Remote Sensing* 8(7): 598. DOI 10.3390/rs8070598.
- Khazendar A., Fenty I.G., Carroll D., Gardner A., Lee C.M., Fukumori I., Wang O., Zhang H., Seroussi H., Moller D., Noël B.P.Y., van der Broeke M.R., Dinardo S., Willis J., 2019. Interruption of two decades of Jakobshavn Isbræ acceleration and thinning as regional ocean cools. *Nature Geoscience* 12(4): 277–283.
- King M.D., Howat I.M., Candela S.G., Noh M.J., Jeong S., Noël B.P.Y., van den Broeke M.R., Wouters B., Negrete A., 2020. Dynamic ice loss from the Greenland ice sheet driven by sustained glacier retreat. *Communications Earth & Environment* 1(1): DOI 10.1038/s43247-020-0001-s.
- Lee J.S., Pottier E., 2009. *Polarimetric radar imaging: From basics to applications*. CRC Press. DOI 10.1201/9781420054989.
- Lei Y., Gardner A., Agram P., 2021. Autonomous repeat image feature tracking (autoRIFT) and its application for tracking ice displacement. *Remote Sensing* 13(4): 1–20.
- Lemos A., Shepherd A., McMillan M., Hogg A.E., 2018a. Seasonal variations in the flow of land-terminating glaciers in central-west Greenland using sentinel-1 imagery. *Remote Sensing* 10(12): 1878.
- Lemos A., Shepherd A., McMillan M., Hogg A.E., Hatton E., Joughin I., 2018b. Ice velocity of Jakobshavn Isbræ, Petermann Glacier, Nioghalvfjerdsfjorden, and Zachariæ Isstrøm, 2015–2017, from Sentinel 1-a/b SAR imagery. *Cryosphere* 12(6): 2087–2097.
- Luckman A., Murray T., 2005. Seasonal variation in velocity before retreat of Jakobshavn Isbræ, Greenland. *Geophysical Research Letters*, 32(8): 1–4.
- Mahmoud A.M.A., Novellino A., Hussain E., Marsh S., Psimoulis P., Smith M., 2020. The use of SAR offset tracking for detecting sand dune movement in Sudan. *Remote Sensing* 12(20): 3410.
- Massonnet D., Feigl K.L., 1998. Radar interferometry and its application to changes in the earth's surface. *Reviews of Geophysics* 36(4): 441–500.
- Mottram R., Stendel M., Box J., Mankoff K., Ahlstrøm A., 2021. What happened to Greenland's ice sheet in 2021? *World Economic Forum*, 1 December. Online: <https://www.weforum.org/agenda/2021/12/greenland-ice-sheet-environment-climate-change/> (accessed 31 January 2022).

- Nagler T., Rott H., Hetzenecker M., Wuite J., Potin P., 2015. The sentinel-1 mission: New opportunities for ice sheet observations. *Remote Sensing* 7(7): 9371–9389.
- Neckel N., Zeising O., Steinhage D., Helm V., Humbert A., 2020. Seasonal observations at 79°N glacier (Greenland) from remote sensing and in situ measurements. *Frontiers in Earth Science* 8: 142.
- Riel B., Minchew B., Joughin I., 2021. Observing traveling waves in glaciers with remote sensing: New flexible time series methods and application to Sermeq Kujalleq (Jakobshavn Isbræ, Greenland). *Cryosphere* 15(1): 407–429.
- Rignot E., Mouginot J., Morlighem M., Seroussi H., Scheuchl B., 2014. Widespread, rapid grounding line retreat of Pine Island, Thwaites, Smith, and Kohler glaciers, West Antarctica, from 1992 to 2011. *Geophysical Research Letters* 41(10): 3502–3509.
- Samsonov S., Tiampo K., Cassotto R., 2021. SAR-derived flow velocity and its link to glacier surface elevation change and mass balance. *Remote Sensing of Environment*, 258: 112343.
- Schubert A., Faes A., Kääb A., Meier E., 2013. Glacier surface velocity estimation using repeat TerraSAR-X images: Wavelet- vs. correlation-based image matching. *ISPRS Journal of Photogrammetry and Remote Sensing* 82: 49–62.
- Sohn H.-G., Jezek K.C., van der Veen C.J., 1998. Jakobshavn Glacier, west Greenland: 30 years of spaceborne observations. *Geophysical Research Letters* 25(14): 2699–2702.
- Strozzi T., Luckman A., Murray T., Wegmüller U., Werner C.L., 2002. Glacier motion estimation using SAR offset-tracking procedures. *IEEE Transactions on Geoscience and Remote Sensing*, 40(11): 2384–2391.
- Strozzi T., Paul F., Wiesmann A., Schellenberger T., Kääb A., 2017. Circum-arctic changes in the flow of glaciers and ice caps from satellite SAR data between the 1990s and 2017. *Remote Sensing* 9(9): 947.
- Sun L., Muller J.-P., Chen J., 2017. Time series analysis of very slow landslides in the three gorges region through small baseline SAR offset tracking. *Remote Sensing* 9(12): 1314.
- Torres R., Snoeijs P., Geudtner D., Bibby D., Davidson M., Attema E., Potin P., Rommen B., Floury N., Brown M., Traver I.N., Deghaye P., Duesmann B., Rosich B., Miranda N., Bruno C., L'Abbate M., Croci R., Pietropaolo A., Huchler M., Rostan F., 2012. GMES Sentinel-1 mission. *Remote Sensing of Environment* 120: 9–24.
- Trouvé E., Vasile G., Gay M., Grussenmeyer P., Nicolas J.M., Landes T., Koehl M., Chanussot J., Julea A., 2005. Combining optical and SAR data to monitor temperate glaciers. *International Geoscience and Remote Sensing Symposium (IGARSS)*, Vol. 4, pp. 2637–2640.
- Tuckett P.A., Ely J.C., Sole A.J., Livingstone S.J., Davison B.J., Melchior van Wessem J., Howard J., 2019. Rapid accelerations of Antarctic Peninsula outlet glaciers driven by surface melt. *Nature Communications* 10(1): 1–8.
- Vizcaino M., Mikolajewicz U., Ziemann F., Rodehacke C.B., Greve R., Van Den Broeke, M.R., 2015. Coupled simulations of Greenland Ice Sheet and climate change up to A.D. 2300. *Geophysical Research Letters* 42(10): 3927–3935.
- Willis J., Carroll D., Gardner A., Khazendar A., Wood M., Holland D., 2020. *Glacier forecast: Jakobshavn Isbrae primed for thinning and acceleration*. Preprint, ResearchSquare, pp. 1–23.
- Winsvold S.H., Kääb A., Nuth C., Andreassen L.M., Van Pelt W.J.J., Schellenberger, T., 2018. Using SAR satellite data time series for regional glacier mapping. *The Cryosphere* 12: 867–890.
- Wu Z., Zhang W.H., Liu Y.S., Ren D., Xun J.Z., Bai J.X., 2020. Analysis of the response of glaciers to climate change based on the glacial dynamics model. *Environmental Earth Sciences* 79(19): 1–10.
- Xu X., Ma C., Lian D., Zhao D., 2020. Inversion and analysis of mining subsidence by integrating DInSAR, offset tracking, and PIM technology. *Journal of Sensors* 2020(8): 1–15. DOI 10.1155/2020/4136837.
- Yan S., Guo H., Liu G., Fu W., 2013. Monitoring Muztagh Kuksai glacier surface velocity with L-band SAR data in southwestern Xinjiang, China. *Environmental Earth Sciences* 70(7): 3175–3184.
- Zhao G., Wang L., Deng K., Wang M., Xu Y., Zheng M., Luo Q., 2021. An adaptive offset-tracking method based on deformation gradients and image noises for mining deformation monitoring. *Remote Sensing* 13(15): 2958.
- Zhou J., Li Z., Guo W., 2014. Estimation and analysis of the surface velocity field of mountain glaciers in Muztagh Ata using satellite SAR data. *Environmental Earth Sciences* 71(8): 3581–3592.



Temporal development of the displacement field of the Ponzano landslide in February 2017

Magdalena Łucka^{1, CDFMR}, Ryszard Hejmanowski^{2, CMR}, Wojciech Witkowski^{3, CDFM}

^{1,2,3}AGH University of Krakow, Faculty of Geo-Data Science, Geodesy and Environmental Engineering, Aleja Mickiewicza 30, 30-059 Krakow, Poland; ¹e-mail: magdalena.lucka@agh.edu.pl (corresponding author), <https://orcid.org/0000-0002-0747-6963>; ²e-mail: hejman@agh.edu.pl, <https://orcid.org/0000-0003-1042-4213>; ³e-mail: wwitkow@agh.edu.pl, <https://orcid.org/0000-0003-1042-4213>

How to cite:

Łucka, M., Hejmanowski, R. & Witkowski, W. (2023). Temporal development of the displacement field of the Ponzano landslide in February 2017. *Bulletin of Geography. Socio-economic Series*, 62(62): 137-151. DOI: <http://doi.org/10.12775/bgss-2023-0039>

Abstract. The conducted research determined the temporal evolution of the displacement field for the Ponzano landslide case study. The offset-tracking method, so far used mainly for the relatively rapid but uniform displacement of glaciers, was tested for the 2017 study of the Ponzano landslide in Italy. The suitability of the method for high-resolution TerraSAR-X and medium-resolution Sentinel-1 imagery was investigated. The results proved the applicability of the OT method for studying processes with high and variable displacement dynamics. However, for such purposes, high-resolution radar data are crucial. With an uncertainty in the determination of residual displacements of about ± 1 m, it was shown that the values of residual displacements occurring up to several days after the main phase of landslide movements are within the range of uncertainty but are determinable. The research conducted in the paper filled a gap in the analysis of the phenomenon just after the main movement phase. It allowed determination of the time and speed of extinction of landslide movements.

Article details:

Received: 09 November 2023
Revised: 21 December 2023
Accepted: 30 December 2023

Key words:

displacement field,
rapid landslide,
offset-tracking,
residual displacements,
satellite imagery

Contents:

1. Introduction	138
2. Study area: the Ponzano landslide	139
3. Materials and methods	140
3.1. Datasets	140
3.2. Offset-tracking	140
3.3. Tests of dimensions of the registration window	141
3.4. Uncertainty of the results	141
4. Results	141
4.1. Selection of optimal registration window	141
4.2. Displacements for the main phase of movements based on S-1 data	143
4.3. Temporal evolution of landslide movements	144
4.4. Comparison between calculations from different temporal baselines	145
5. Discussion	146
6. Conclusions	149
Acknowledgement	149
References	150

1. Introduction

Rapid landslides are caused by various factors, both natural and man-made. Therefore, considering observed climate changes and spreading human activity, they currently affect most parts of the world (Maraun et al., 2022). Global warming influences temperature and precipitation frequency and amount, which are expected to increase the number of shallow landslides and thus enlarge the population affected by landslide risk (Gariano & Guzzetti, 2016; Jakob, 2022). In permafrost areas, melting snow and permafrost are leading to the destabilisation of the soil (Kim et al., 2021). More frequent and intense rainfalls affect the stability of slopes in Europe, South America and south-eastern Asia. The other natural factors that trigger landslides include earthquakes, volcanoes, and river or glacier erosion. On the other hand, human activity, including deforestation, irrigation, producing waste piles, open-pit mining and developing infrastructure in hilly areas, also destabilise slopes and, combined with other factors, might result in a rapid landslide. Due to the severity of the effects of rapid landslides, including the destruction of infrastructure such as roads or houses, the devastation of crops, and even health injuries, the monitoring of landslides, understanding their mechanisms, and further modelling and predicting are crucial (Fell et al., 2007; Hung, 2007). The increase in landslide hazards in many densely populated regions of the world today poses enormous challenges for scientists and researchers of these phenomena. In particular, the importance of monitoring and early warning of landslides is growing.

A wide variety of techniques are used for landslide monitoring that can be divided into such groups as remote sensing, geodesy, geotechnics, geophysics or hydrology (Auflič et al., 2023). Most of them are in-situ methods, except for the remote-sensing group, which is currently widely used for various purposes such as predicting landslides, susceptibility mapping, monitoring displacements, detection and even modelling or hazard management (Delacourt et al., 2007; Scaioni et al., 2014; Zhao & Lu, 2018; Casagli et al., 2023). In the remote-sensing group, especially useful are SAR (Synthetic Aperture Radar) data as they deliver information regardless of daylight or weather conditions. Thus, they are widely used for landslide monitoring including displacement measurement utilising mainly coherence-based methods (Wasowski & Bovenga, 2014; Raspini

et al., 2019; Refice et al., 2019; Ao et al., 2020; Jia et al., 2020; Wang et al., 2022; Huang et al., 2023; Nikolakopoulos et al., 2023). Nevertheless, SAR interferometry (InSAR) cannot be used in all cases because of the coherence loss in dynamically moving areas. Among the remote-sensing monitoring methods, an offset-tracking (OT) technique might be used as an alternative for displacement determination. This OT does not rely on phase information but on searching corresponding intensity patches between two images using cross-correlation, which makes the technique suitable for monitoring rapid movements. So far, the use of this method has been mainly limited to glacial areas, which are characterised by relatively fast movements. However, it has been proven to be particularly useful in landslides (Wang et al., 2016; Cai et al., 2017; Solari et al., 2018; Amitrano et al., 2019; Li et al., 2019). The utility of this method strongly relies on the input image resolution, as the accuracy determined by the method is measured as part of pixel size. The current development of new, high-resolution SAR sensors might improve the possibility of using the OT method to detect smaller and not-extensive movements that occur rapidly. These new possibilities of OT methods became one of the objectives of the study, in terms of one of the most spectacular landslide phenomena of recent years in Europe, the Ponzano landslide (2017). Research into the nature of landslide movements in Ponzano carried out between 2017 and 2020 mainly by Italian scientists (Solari et al., 2018; Calista et al., 2019) might, combined with the new OT-based information about the displacement field, help to find new explanations or add new aspects to the current state of knowledge.

Considering the need to monitor and understand the mechanism of rapid landslides, the research examines the utility of medium (Sentinel-1) and high-resolution (TerraSAR-X) SAR datasets for landslide monitoring and determining optimal processing parameters. It also investigates the scale of movements that can be reliably detected by remote-sensing methods and the temporal development of the displacement field in Ponzano. It allows for determining the displacements in the main phase of movements and post-landslide activity. This study also fills the gap in the monitoring of the Ponzano landslide by deriving the displacement values between the main-phase and the post-landslide *in-situ* monitoring. Therefore, it contributes to a better understanding of the mechanism of the Ponzano landslide.

2. Study area: the Ponzano landslide

The Ponzano landslide is in the central-eastern part of Italy, in the Teramo Province of the Abruzzo region (Fig. 1a; Fig. 1b). It is a very hilly area (Fig. 1d) affected by a significant number of various landslides. The landslide covers an area of ~57 ha (566,759 m²). It is east-southeast facing and the slope ranges from 4° to up to 20°, with a mean value of 11° (Fig. 1e). The flattest part is located in the centre of the landslide at the south. Some scarps appear mainly in the upper part of the landslide where the steepest slopes are observed and in the eastern part where the slopes range from 15° to 20°. The surface is covered mainly by green areas such as grass, crops and some trees (Fig. 1c). In the upper part of a landslide, there are small groups of buildings and a few roads.

The bedrock in the study area is made of pelitic-arenaceous layers. To the west of the landslide boundaries is a layer of sandstone with thin clay levels with a thickness of 30 to 60 m. The region inside the

landslide boundaries consists mainly of clays with sandstone layers and silt and clay with sand, covered by colluvial deposits with a thickness of up to 15 m (Fig. 2). The landslide was activated in the top layer of colluvial deposits and the upper part of the clays (Calista et al., 2019). On February 12, 2017, the region of Ponzano, which is known to be an unstable area, was reactivated mainly due to the intensive rainfall and snowfall that resulted in a large landslide (Solari et al., 2018). It is a complex formation with two components: rotational sliding in the upper part of a landslide and earth flow in the lower part. Before the landslide was reactivated, the area had been stable or slightly moving at a level of 10 to 40 cm total over almost 14 years (Solari et al., 2018). In a phase of major movements, the landslide developed suddenly. In the following five months, it slowed down, but movements totalling almost 75 cm were detected (Allasia et al., 2019). As a result of the movements, local roads and some buildings were seriously damaged, and several dozen inhabitants had to be evacuated.




Fig. 1. Location of the research area (a) on the background of the whole country, (b) within Teramo province, (c) land cover and border of landslide, with location of borehole and cross-section, (d) heights derived from TIN ITALY 10 m DEM (Tarquini et al., 2012) and (e) slope over an AOI




Fig. 2. Cross-section through the Ponzano landslide (a) and geological profile for S1 borehole (b) (modified from Calista et al., 2019)

3. Materials and methods

3.1. Datasets

This study utilises two Sentinel-1 (S-1) and three high-resolution TerraSAR-X (TSX) SAR images. Collected data were used as input for displacement calculations with the OT method. The Single Look Slant Range Complex (SSC) products were used in case of TSX satellite, collected in Stripmap mode and from the ascending track. The polarisation of the data is horizontal (HH). The TSX sensor is classified as high-resolution as the slant range resolution is ~1.2 m. The range and azimuth spacings, which are crucial parameters for the OT method, are 1.36 m and 2.19 m, respectively. The TSX data utilised in this study were acquired in the following way: 1st – just before the landslide occurred; 2nd – immediately after the phase of the main movements, 3rd – after the next 11 days. Those three SAR images were processed in various combinations to obtain displacements in the main phase of the landslide, in a few days after, and in the whole period cumulatively (Table 1). This allows observation of how the landslide movements developed during the analysed period.

From the S-1 mission, the Single Look Complex (SLC) products were used. The data were acquired

in the Interferometric Wide (IW) mode and from an ascending track. In this study, only the cross-polarisation (VH) data were utilised. Collected S-1 images have a range spacing of 2.33 m and an azimuth spacing of 13.92 m. It is worth noting that range spacing is ~1.2 times larger compared to TSX data, and in an azimuth direction, the difference is even more significant. The S-1 azimuth spacing is more than six times coarser than the TSX's. To investigate the impact of this difference, two S-1 images were collected covering the phase of main movements (Table 1) to compare results to TSX output. The image pairs with ID 2, ID 3, and ID 4 are referenced in the following text as period 1, period 2, and period 3.

3.2. Offset-tracking

Displacements for both sensors were calculated using the OT method implemented in the Gamma Software. The selected method uses intensity information from SAR data to find corresponding patches between two images from different days. The cross-correlation between image patches is calculated for a selected size of a registration window. The patch with the highest cross-correlation peak is selected as a corresponding image part (Strozzi et al., 2002). In the following steps, the offsets in range and azimuth directions are calculated. The

Table 1. Satellite radar image pairs acquired by the Sentinel-1 and TerraSAR-X mission used in the study

ID	Reference image [dd/mm/yyyy]	Secondary image [dd/mm/yyyy]	Satellite	Temporal Baseline [days]	Perpendicular Baseline [m]	Geometry
1	06/02/2017	18/02/2017	S-1	12	36	ascending
2	10/02/2017	21/02/2017	TSX	11	222	ascending
3	21/02/2017	04/03/2017	TSX	11	136	ascending
4	10/02/2017	04/03/2017	TSX	22	87	ascending

Copernicus 30 m DEM (Digital Elevation Model) was utilised in the preprocessing of the dataset. The OT was employed in two iterations. The first one is to determine the initial offsets, and the second one is to improve the quality of the results. At this step, various sizes of registration windows were investigated to obtain the optimal output. The results were also filtered with a fast spatial filter using a quadratic weighted average. After each iteration, the results were also filtered based on determined thresholds: the minimum and maximum range and azimuth pixel offsets, and the cross-correlation value. The pixel offsets were determined separately for each calculation period, and the minimum cross-correlation value was established at 0.2 to remove displacement values that were determined with the lowest quality. The final results contained the ground range and azimuth displacement values in metres and the magnitude displacements, which were used in further analyses.

3.3. Tests of dimensions of the registration window

To obtain optimal displacement values, calculations for period 1 were performed in various window dimensions for range and azimuth directions. Window sizes from 16 pxl × 16 pxl (range × azimuth dimension) to 256 pxl × 256 pxl were tested. The window dimensions were doubled in each iteration, and near-quadratic windows were also tested (e.g. 256 pxl × 128 pxl). To determine which results are most suitable, analyses of accuracy around the landslide were performed. Two buffers around

landslide boundaries, with a 200 m and 1000 m width, were constructed for this purpose (Fig. 3). The landslide area was excluded from the analysis, and the generated buffer zones intersect with each other. All produced rasters of displacements in range and azimuth directions were cropped only to the extent of the buffer zones. Each cropped raster was analysed in terms of the mean value and standard deviation in the selected buffer. It is assumed that the area around the landslide boundaries is stable, so the displacements in the buffer zones should be equal to 0 m. Based on the performed statistical analysis, the optimal window size was selected for further processing of the dataset.

3.4. Uncertainty of the results

The final results are presented as the magnitude of the movements (Mag), which is determined as a resultant of azimuth (Az) and range (Rg) displacements. Thus, the uncertainty (standard deviation – σ) of each magnitude raster based on the uncertainties of its components, considered as independent variables might be defined as follows:

$$\sigma_{Mag} = \sqrt{\sigma_{Az}^2 + \sigma_{Rg}^2} \quad (1)$$

Determination of uncertainty is also possible by analysing displacement in three time periods (from $P1$ to $P3$). Residual values of movements (Res) determine the accuracy of the results. Their uncertainties might be described in the following way based on the rules of error propagation:

$$Res = Mag_{P3} - (Mag_{P1} + Mag_{P2}) \quad (2)$$

$$\sigma_{res} = \sigma_{Mag} \sqrt{3} \quad (3)$$

Assuming that the uncertainties for all periods are the same, uncertainty can be calculated by equation (3).

4. Results

4.1. Selection of optimal registration window

The first stage of research was to determine the size of the registration window for the Ponzano area. Two TSX acquisitions from 10/02/2017 and 21/02/2017 were used. The mean values of displacements in range and azimuth directions




Fig. 3. Schema of buffers used for analysis of results based on various registration windows

were determined in the buffer zones around the Ponzano landslide. Calculated values with their standard deviations show the accuracy and amount of noise for each registration window size in the 200 m (Fig. 4a) and 1000 m (Fig. 4b) buffers. Increasing window size presents smaller standard deviations and mean values closer to 0 m in both directions. However, the results are strongly smoothed, and the details of the displacement pattern are invisible. Reducing window dimensions allows the detection of more details, but the amount of noise visible on

the output is increasing. As an effect, small window dimensions reduce the clarity and reliability of the results. Moreover, in the case of smaller windows, some patterns cannot be observed, and the detection of more significant movements is limited. Considering the trade-off between details and accuracy, the window size of 64 pxl × 64 pxl was selected as an optimal source of information. On the spatial distribution of displacement, areas of more intense and slower movements can be distinguished, providing accurate insight into the displacement




Fig. 4. Relationship between window size and noise amount in (a) 200 m and (b) 1000 m buffer around the landslide




Fig. 5. Spatial distribution of displacements for landslide and selected buffers based on TSX data for period 1 in a 64 pxl × 64 pxl window

field pattern (Fig. 5). A detailed description of the field and its temporal development is provided in Section 4.3. Simultaneously, in the selected buffers of 200 m and 1000 m, the displacement values around 0 m are dominant. The mean values of displacement in both directions and for both buffers are in the range of 2–10 cm. Their standard deviations vary between 0.39 m and 0.61 m. The highest mean value of displacement was 0.10 m for the range direction in the 200 m buffer, and it accounts for 7% of the pixel size of the TSX data. The standard deviations stand in all cases for ~25% of the pixel size in both directions. For the 1000 m buffer, the chart shows slightly higher values of mean and standard deviation. Nevertheless, the same window size presents an acceptable trade-off between details and accuracy. The selected optimal window size was utilised for all periods for TSX data, and, for S-1 data, the corresponding window size was calculated, considering the metric dimensions of the registration box.

4.2. Displacements for the main phase of movements based on S-1 data

Selected in Section 4.1 registration window of 64 pxl × 64 pxl for TSX data corresponds to approximately 90 m × 140 m. To obtain a similar terrain window size for S-1 data, the displacements were calculated in a registration window of 38 pxl × 10 pxl. The results present displacement in range and azimuth directions, as well as magnitude displacement (Fig. 6) over a period covering the main phase of landslide movements. In the range direction, the maximum displacements within the landslide boundaries reach 9 m in the lower part. In the upper part, displacements fluctuate around 8 m. The blurry area of the landslide border can be observed. Nevertheless, the noises observed outside the landslide boundaries also reach high values of several metres, which makes the derived results unreliable, and results present rather random data than the real displacement values. The distribution of displacements in the azimuth direction varies




Fig. 6. Displacement values calculated in the period 06/02/2017–18/02/2017 based on Sentinel-1 images in a 38×10 pixel window

between -10 m and $+5$ m within the marked borders. The highest negative values are observed in the upper part of the landslide, which is consistent with the results from the TSX sensor. The quality of the results in azimuth directions is much lower compared to the range directions. It is caused by such factors as a highly coarser resolution for azimuth direction (almost 14 m) and, at the same time, a smaller scale of movements to be detected. For magnitude directions, the errors and noises from both directions cumulate and, as a result, even outside the landslide boundaries, a large scale of detected movements is observed, which shows the unreliability of the obtained values. Nevertheless, the spatial distribution of the movements within the landslide border is comparable to the TSX results, with the highest peaks at the highest part of the landslide and in the lower part. Simultaneously, all displacement values seem to be slightly underestimated compared to the high-resolution sensor. No further analyses based on S-1 data were conducted for the next periods because of the large amount of noise in the results, even in the detection of large-scale movements.

4.3. Temporal evolution of landslide movements

For the selected optimal window size, the calculations for periods 1 to 3 were performed, revealing the temporal development of the displacement field for the Ponzano landslide. The range, azimuth and magnitude displacements over those three periods were analysed (Fig. 7). In order to analyse only displacements that are the most reliable, the obtained displacement maps were masked by cross-correlation for the patch (ccp) at a value of 0.2 . For all periods, the main component of a shift occurred in the range direction. The strong eastern component and negative values for azimuth displacement show that the main flow of the landslide stays in agreement with the general slope direction of the terrain. Although most of the displacement took place in period 1, residual displacement could be observed in the second period. All movements detected by the OT method are within the borders of the Ponzano landslide, according to the database provided by the International Programme on Landslides (IPC).

In period 1, in the range direction, the displacement values are within -0.15 – 16.8 m. The largest displacement is observed in the upper part of the landslide located in the western part of the AOI. There is a visible cut-off between the stable area and

the landslide. Most of the observed displacements exceed the value of 8 m. In the lower part, due to the low ccp values, the precise determination of the displacement pattern is challenging. The most significant azimuth displacement was observed in the upper part of the landslide, with values ranging from ca -6.5 m to -8.0 m. In the central part, the movements reach values around 3 m. In the lower part, displacements gradually decrease. On the magnitude map, three areas with the highest displacement values can be distinguished. The first one is at the top of the landslide with a maximum value of ~ 16.8 m; the second one is on the southern part, slightly below the first area, with a maximum of 15.5 m; and the last one is at the lower part of the landslide, where the slope is steeper, with a maximum movement equal to 15.1 m.

In period 2, the azimuth displacements vary in the range of ± 0.23 m. Considering the standard deviation of the results obtained in Section 4.1, which can be considered the accuracy of the method, the azimuthal results might be considered negligible. Taking into account the aforementioned small values of azimuth shifts, the range displacements are almost identical to the magnitude movements. Displacements are significantly smaller in period 2 than in period 1, suggesting that the main phase of the movements is already finished. Nevertheless, the displacements at a maximum of 1.4 m were still observed in the period of 9 to 20 days after the landslide was triggered, suggesting that the deformation process lasted for the next few weeks. The most significant difference between period 1 and period 2, besides the magnitude of displacements, is the location of the main movements. In period 1, the maximum values were focused in the upper part of the landslide, whereas in period 2, the largest displacements were observed in the lower part of the landslide, especially below the area where the significant slope steepening is observed.

Period 3 comprises displacements that occurred in period 1 and period 2 but were calculated independently. It is visible that the main shift occurred in a range direction, but in the upper part of the landslide the influence of the azimuthal shift is also observed. The range movements reach a maximum of 17 m in the upper part (the steepest part of the landslide) and in the lower part (both in the north and south parts). In the azimuth direction, mainly the upper part of a landslide shows the displacement reaching 7.5 m. In the central part of the AOI, the azimuth displacements vary by around 3 m. The magnitude movements reach peaks in the upper part with a value of 18 m and in the lower, southern part with a maximum of 19.5 m.




Fig. 7. Displacements derived by TSX data in three analysed periods in range and azimuth directions, and cumulative with masked areas with ccp at 0.2 value

4.4. Comparison between calculations from different temporal baselines

Period 3 should comprise period 1 and period 2 displacements. It is assumed that the difference between cumulative movements from period 1 and period 2 should be equal to those detected in period 3. The magnitude displacements were used for this comparison. The joint part of the masked raster data for all periods was used to determine the discrepancies between period 3 and the summed shorter periods. Those residuals show the inaccuracy of the calculation method, as the input SAR data had identical features for all periods and covered the same dates. The histogram (Fig. 8b) shows that the mean value (μ) of residuals is 0.03. The standard deviation (σ) is equal to 0.94, which means that 68% of all residuals range from -0.91 m to 0.97 m. About 30% of all residuals reach values above 1 m. There are two main areas where the most significant discrepancies are located (Fig. 8a). The first one is in the upper part of the landslide, where the highest displacement values

were identified. The second area is in the southern part, near the south border of a landslide. Positive values of the residuals suggest an overestimation of the displacement values over a longer period. Over the major part of the landslide, including the central area, no significant residuals are observed.

Presented in Section 4.1, the analysis showed that for a buffer zone of 200 m, the uncertainty of azimuth and range displacement reached 0.55 m and 0.39 m, respectively. Based on equations from (1) to (4), the standard deviation for magnitude displacements is 0.67 m, and the uncertainty of the calculated residuals is equal to 1.17 m. Figure 8b shows that the standard deviation of residuals is 0.94, which means that unmasked values are within the accuracy of the utilised OT method determined in Section 4.1. Moreover, the applied mask was based on a ccp value, so mostly values that were determined with too low accuracy were removed from the analysis. The presented analysis justifies the use of ccp at a level of 0.2 as a reasonable threshold.




Fig. 8. Residuals between magnitude displacement determined in a long period and cumulative short periods: (a) spatial distribution and (b) histogram of residuals

5. Discussion

The conducted analyses present that even though the OT technique was primarily designed for monitoring glacial areas, it is possible to obtain reliable displacement values by this method for rapid landslides, such as for the Ponzano landslide. Nevertheless, a comparison of the S-1 and TSX datasets revealed that, for a significantly smaller extent of the study area, the medium-resolution S-1 data cannot deliver satisfactory results, in contrast to the TSX imagery. Further investigation about the possibility of applying the OT method in the landslide case study included an analysis of the influence of registration window size on the quality of the results and the accuracy of the obtained displacement maps. The results of the analyses presented in Section 4.1 lead to the conclusion that the size of the optimal window is $64 \text{ pxl} \times 64 \text{ pxl}$. The selected window size reflects the compromise between the visible details in the results and the amount of noise and errors in the background. Similar conclusions are also presented by Wegmüller et al. (2002) and Amitrano, Guida, Di Martino et al. (2019). The former indicates that windows of $64 \text{ pxl} \times 64 \text{ pxl}$ or $128 \text{ pxl} \times 128 \text{ pxl}$ can be considered a reasonable compromise in the OT method. The latter points out that $64 \text{ pxl} \times 64 \text{ pxl}$ windows is the minimum recommended size to obtain reliable values.

Based on the analysis of the displacement values outside the landslide boundaries for the selected optimal window size, the accuracy of the OT method could be established. The mean value

for the background ranged from 2 cm to 10 cm, depending on the buffer size and displacement direction. These values correspond to 1% to 7% of pixel size and reflect the mean error of the output displacement maps. Nevertheless, the standard deviation in the background varied from 0.39 m to 0.61 m, which corresponds to ~25% of the pixel size. Those standard deviations might be considered the accuracy of the OT method in this particular case study. In the current state of the art, it is assumed that the OT accuracy might reach 5% of the pixel size (Wegmüller et al., 2002). In the analysed Ponzano landslide case, the obtained accuracy is lower. However, it is worth noting that the calculations of the initial accuracy are performed on the raw results without rejection of the pixels, where cross-correlation values are low. Whereas the analysis of the temporal evolution of the landslide movements in Section 4.3 is performed on the filtered displacement maps, considering only pixels with a ccp higher than 0.2 to provide high-quality data.

In addition, this study reveals the temporal evolution of the displacement pattern for the Ponzano case and fills the gap between existing studies about the landslide evolution in 2017. In this study, for the first time, the pace of the displacements is investigated in detail on a short time scale, allowing us to determine the period in which the dangerous movements might still occur in the landslide area. The existing studies were focused mainly on pre-landslide (Solari et al., 2018) or post-landslide displacements (Allasia et al., 2019). For pre-landslide monitoring, remote-sensing

techniques based on SAR imagery were used. Solari et al. (2018) applied the SqueeSAR method and a combination of Sentinel-1 and Radarsat-2 images to provide information about displacement 14 years before the Ponzano landslide was activated in 2017. This study revealed that, since 2003, the cumulative displacement in the analysed area ranged from 10 cm to 40 cm. In the same study, the rapid motion tracking algorithm was used to map displacement in the main phase of landslide movements. These results confirm that the most severe displacement occurred in the crown of the landslide and the displacement pattern confirms observations from Section 4.3. Calista et al. (2019) also presented the displacement map covering the main phase of the landslide movements based on the UAV data, with values reaching even 19 m in the south-easterly direction. The general spatial distribution of the movements and the scale of the detected displacements are consistent with the results of this study. Nevertheless, a direct comparison of displacement values is impossible as the UAV-derived map covers a much longer period. The UAV pre-landslide data are from 2010–13, and the post-landslide data acquisition took place in May 2017 – three months after the landslide was triggered. It can be assumed that the UAV displacement map presents mainly the effect of the February 12 landslide, though some pre- and post-landslide displacements might affect the results presented in Calista et al. (2019). In this study, the cumulative displacements cover only 22 days around the main phase of movement. Nevertheless, the UAV maps provide the most reliable results to compare with the results obtained in this study by the OT methods. The three areas of maximum movement can be observed in both UAV- and OT-derived maps. The areas are consistent, which makes the OT results from the study more reliable. The post-landslide in-situ monitoring carried out by Alasia et al. (2019), shows that until July 2017, some displacements were still observed in Ponzano, reaching a maximum of 72 cm in the upper part of the landslide. Nevertheless, the in-situ monitoring started on February 23, which resulted in a data gap between the date of triggering the landslide and the start of its monitoring. This study aimed to fill this gap and derive information about displacement that occurred right after the main phase of movements slowed down. Such information might be crucial for inhabitants of areas where rapid landslides occur, as it helps to establish the duration of landslide activity and the scale of those residual displacements. A synergy of previous studies and this research provides a more detailed insight into

the mechanism of the Ponzano landslide formation, revealing the pace of the displacements for the selected benchmark (Fig. 1c). First, the confidence interval for the OT results was determined. For this purpose, the Student's t-test with the Welch amendment was applied to two groups of the data (period 3 and the sum of period 1 and period 2) around the benchmark. This determined a 95% confidence interval of -0.8 m to $+1.5$ m. Then, the theoretical function was fitted to the OT results. Due to the rapid growth of displacement values in the initial part of the time series and the more or less constant value for further arguments, it was decided to use one of the functions used in geostatistics, the pentaspherical model (4). Fitting was performed to ensure that the pentaspherical model was within the 95% confidence interval. Utilising the land displacement model, the velocities of land movements (5) were determined.

$$Mag(t) = Mag_0 \left(\frac{15}{8} \left(\frac{t}{t_0} \right) - \frac{5}{4} \left(\frac{t}{t_0} \right)^3 + \frac{3}{8} \left(\frac{t}{t_0} \right)^5 \right) \quad (4)$$

$$Velocity(t) = \frac{\partial Mag(t)}{\partial t} \quad (5)$$

where: $Mag(t)$ – land displacement in time, t – time, Mag_0 – maximum value of land displacement in t_0 – the moment of occurrence of the maximum land displacement value.

Assuming that 'til the end of May, the post-landslide monitoring covered the total displacement value, in the first phase of the movement, consisting of the date of landslide triggering and nine more days, 92% of the total movements were observed by the OT technique. The maximum estimated velocity in this period reached 2.1 m/day at the beginning of the movements (Fig. 9). In this stage, the most significant movements were observed near the landslide corona. This maximum estimated velocity is derived from the availability of TSX imaging dates, so the most likely value of velocity is significantly higher. In the following 11 days observed by the OT method, 4% of the total movement was observed. At this point, the movements were mostly observed in the lower part of the landslide, especially beneath the scarps zone. The maximum estimated velocity at the beginning of this period was 0.56 m/day. It is important to note that in this stage, covering days from 9 to 20 after the triggering of the landslide, residual displacements still reach even 1.4 m. Such

a scale of movements means further instability of this region, which might still have negative consequences for inhabitants and infrastructure. In the following days, until the end of May, the post-landslide in-situ monitoring revealed the last 4% of the movements with an average speed of 0.03 m/day. The UAV until the beginning of May showed displacements with a maximum value similar to those from the OT technique; however, the average estimated speed in this case is 0.16 m/day. Considering the uncertainty of the OT data and the errors of the other measurement techniques, it might be concluded that the utilised OT method derived reliable results for the Ponzano landslide based on the TSX data.

Despite the successful application of the OT method in the Ponzano landslide case, the aforementioned technique might not provide reliable results for some rapid landslides. The resolution of the input dataset and the scale of the movements remain limitations of the OT procedure. Section 4.2 points out that S-1 images, which are characterised by coarser resolution compared to TSX, did not provide reliable results even for the main phase of landslide movements. On the other hand, high-resolution datasets enabled captioning

movements at the level of a few dozen centimetres. However, such datasets are not as easily accessible as S-1 images. Another limitation is connected with the change in land cover that might accompany a rapid landslide. Too severe changes in land cover result in problems finding corresponding patches on the pair of SAR images. As a result, the application of the OT method in such cases can be challenging. Nonetheless, knowledge gained by studying particular cases like Ponzano might be transferred to similar landslide events.

Rapid landslides have both short- and long-term socio-economic effects on the local population, as well as national consequences. Italy, being one of the European countries with the highest landslide risks, also suffers from the highest economic loss due to landslide activities, estimated at 3.9 billion euros per year (Haque et al., 2016). The expenses affect both public and private properties, and they can be separated into direct costs such as replacing residents or restoring infrastructure and indirect costs such as changing land use cover, which results in, for example, the destruction of agricultural lands (Schuster, 1996). In the event of the Ponzano landslide, 35 residences were evacuated, with many collapsing or sustaining




Fig. 9. Time-series for selected benchmark: combined results from this study, UAV and post-landslide monitoring

severe damage. Parts of the roadways at the corona and farther down the landslide were also damaged, resulting in additional costs for road repairs. Most of the damaged regions were used for agricultural reasons, notably olive oil plants. Ground movement and slope destabilisation may result in the loss of growing products. Furthermore, approximately 120 people were forced to leave their homes, either permanently or temporarily. The analyses performed in the study provide more accurate insight into the exact damages caused by the Ponzano landslide, and the technique utilised may also contribute to hazard management in other landslide incidents. Firstly, the OT technique and SAR data analysis can rapidly and safely determine the spatial extent of the disaster, assisting in estimating financial losses due to land changes and mapping buildings in hazard zones that may be harmed. Furthermore, this investigation demonstrated that residual movements could persist in the impacted areas even several days after the landslide was triggered. Consistent monitoring of those movements can aid decision-making and risk assessment by providing information about the safety of the analysed region and the slope's stability. Remote monitoring may also reveal locations that are particularly vulnerable due to significant land movements and should be better safeguarded and closed off to residents. As a result, the OT technique and high-resolution imagery can be utilised to estimate the duration of the dynamic movement phase that threatens people and infrastructure.

6. Conclusions

The current study investigates the feasibility of using the OT technique to detect landslide displacement based on the example of the Ponzano landslide. A key outcome of the studies is new information about the temporal evolution of the displacement field for this landslide. The performed analyses derived information about the scale of movements in a short time scale for the first time, revealing that, in the main phase of the movements, about 92% of all registered displacements were detected. Moreover, during the following 11 days, the residual movements were also observed with their maximum displacement value reaching 1.4 m, which represents the next 4%. The comparison of calculations from various temporal baselines indicates that the values of residual displacements are reliable, as they exceed the uncertainty of the calculations. Those results show for the first time that, after

the main phase of the movements, there are still some fading displacements that might threaten the local inhabitants. The last 4% of displacements were observed in the next three months, with a mean velocity of 0.03 m/day. These results showing the pace of an evolving landslide are especially important in the light of increasing intensity of rainfalls and extreme weather conditions that lead to the instability of the ground and in consequence to a higher number of rapid landslides across the world.

Furthermore, the suitability of using medium and high-resolution SAR data was determined. The medium-resolution S-1 SAR data and high-resolution TSX images were used to test the parameters of the OT method and obtain displacement maps for three periods of the landslide's evolution: the main phase of the movement (until 9 days after the landslide was triggered), the phase of residual movements (from 9 to 20 days after triggering), and the longer period covering both previous phases.

The presented results indicate that the OT method, mainly developed for monitoring glacial areas, can also be successfully applied to rapid landslides to quickly and safely map the size of the disaster. Significantly higher quality was obtained for the high-resolution datasets, which enabled the measuring of the main phase of the movements but also of residual displacements that occurred in the several following days. During the testing phase, the optimal registration window size, which is one of the main parameters of the used method, was established at the level of 64 pxl × 64 pxl. For such input data, the uncertainty of results was calculated as ± 0.39 m in range and ± 0.61 m in azimuth direction, which represent ~25% of the pixel size, considering no filtering by the cross-correlation value.

European countries and other regions in the world will faced an increasing landslide problem in the coming years as a result of climate changes. The impact of these changes on the sense of security of local communities in landslide areas must be addressed. The research presented in this article is a step towards a better understanding of the mechanism of landslides, and thus represents a certain contribution to solving the socio-economic problems of modern societies.

Acknowledgement

The authors acknowledge the European Space Agency (ESA) for providing Sentinel-1 satellite

radar images. The presented research is supported by the “Excellence Initiative—Research University” programme for the AGH University of Science and Technology. All high-resolution datasets were accessed via the ESA Third Party Missions programme as a part of the projects: ID 70186 and ID PP0087663.

References

- Allasia, P., Baldo, M., Giordan, D., Godone, D., Wrzesniak, A. & Lollino, G. (2019). Near Real Time Monitoring Systems and Periodic Surveys Using a Multi Sensors UAV: The Case of Ponzano Landslide. In *IAEG/AEG Annual Meeting Proceedings*, San Francisco, California, 2018, 1(2): 303–310. Springer International Publishing. DOI: https://doi.org/10.1007/978-3-319-93124-1_37.
- Amitrano, D., Guida, R., Dell’Aglio, D., Di Martino, G., Di Martire, D., Iodice, A., Costantini, M., Malvarosa, F. & Minati, F. (2019). Long-Term Satellite Monitoring of the Slumgullion Landslide Using Space-Borne Synthetic Aperture Radar Sub-Pixel Offset Tracking. *Remote Sensing*, 11(3): 369. DOI: <https://doi.org/10.3390/RS11030369>.
- Amitrano, D., Guida, R., Di Martino, G. & Iodice, A. (2019). Glacier Monitoring Using Frequency Domain Offset Tracking Applied to Sentinel-1 Images: A Product Performance Comparison. *Remote Sensing*, 11(11): 1322. DOI: <https://doi.org/10.3390/rs11111322>.
- Ao, M., Zhang, L., Dong, Y., Su, L., Shi, X., Balz, T. & Liao, M. (2020). Characterizing the evolution life cycle of the Sunkoshi landslide in Nepal with multi-source SAR data. *Scientific Reports*, 10(1): 1–12. DOI: <https://doi.org/10.1038/s41598-020-75002-y>.
- Auflič, M. J., Herrera, G., Mateos, R. M., Poyiadji, E., Quental, L., Severine, B., Peternel, T., Podolszki, L., Calcaterra, S., Kociu, A., Warmuz, B., Jelének, J., Hadjicharalambous, K., Becher, G. P., Dashwood, C., Ondrus, P., Minkevičius, V., Todorović, S., Møller, J.J. & Marturia, J. (2023). Landslide monitoring techniques in the Geological Surveys of Europe. *Landslides*, 20(5): 951–965. DOI: <https://doi.org/10.1007/S10346-022-02007-1/FIGURES/7>.
- Cai, J., Wang, C., Mao, X., Wang, Q., Lu, Z., Li, Z., Tomas, R. & Gloaguen, R. (2017). An Adaptive Offset Tracking Method with SAR Images for Landslide Displacement Monitoring. *Remote Sensing*, 9(8): 830. DOI: <https://doi.org/10.3390/RS9080830>.
- Calista, M., Miccadei, E., Piacentini, T. & Sciarra, N. (2019). Morphostructural, Meteorological and Seismic Factors Controlling Landslides in Weak Rocks: The Case Studies of Castelnuovo and Ponzano (North East Abruzzo, Central Italy). *Geosciences*, 9(3): 122. DOI: <https://doi.org/10.3390/GEOSCIENCES9030122>.
- Casagli, N., Intrieri, E., Tofani, V., Gigli, G. & Raspini, F. (2023). Landslide detection, monitoring and prediction with remote-sensing techniques. *Nature Reviews Earth & Environment*, 4(1): 51–64. DOI: <https://doi.org/10.1038/s43017-022-00373-x>.
- Delacourt, C., Allemand, P., Berthier, E., Raucoules, D., Casson, B., Grandjean, P., Pambrun, C. & Varel, E. (2007). Remote-sensing techniques for analysing landslide kinematics: a review. *Bulletin de La Société Géologique de France*, 178(2): 89–100. DOI: <https://doi.org/10.2113/GSSGFBULL.178.2.89>.
- Fell, R., Glastonbury, J. & Hunter, G. (2007). Rapid landslides: The importance of understanding mechanisms and rupture surface mechanics. *Quarterly Journal of Engineering Geology and Hydrogeology*, 40(1): 9–27. DOI: <https://doi.org/10.1144/1470-9236/06-030>.
- Gariano, S.L. & Guzzetti, F. (2016). Landslides in a changing climate. *Earth-Science Reviews*, 162: 227–252. DOI: <https://doi.org/10.1016/j.earscirev.2016.08.011>.
- Haque, U., Blum, P., Haque, U. & Blum, P. (2016). Costs and deaths of landslides in Europe. EGU General Assembly, 18, EPSC2016-12758. <https://ui.adsabs.harvard.edu/abs/2016EGUGA..1812758H/abstract>
- Huang, H., Ju, S., Duan, W., Jiang, D., Gao, Z. & Liu, H. (2023). Landslide Monitoring along the Dadu River in Sichuan Based on Sentinel-1 Multi-Temporal InSAR. *Sensors*, 23(7): 3383. DOI: <https://doi.org/10.3390/S23073383>.
- Hungr, O. (2007). Dynamics of rapid landslides. *Progress in Landslide Science*, 47–57. DOI: https://doi.org/10.1007/978-3-540-70965-7_4/COVER.
- Jakob, M. (2022). Landslides in a changing climate. In *Landslide Hazards, Risks, and Disasters*, 505–579. Elsevier. DOI: <https://doi.org/10.1016/B978-0-12-818464-6.00003-2>.
- Jia, H., Wang, Y., Ge, D., Deng, Y. & Wang, R. (2020). Improved offset tracking for predisaster deformation monitoring of the 2018 Jinsha River landslide (Tibet, China). *Remote Sensing of Environment*, 247: 111899. DOI: <https://doi.org/10.1016/J.RSE.2020.111899>.

- Kim, H., Lee, J.-H., Park, H.-J. & Heo, J.-H. (2021). Assessment of temporal probability for rainfall-induced landslides based on nonstationary extreme value analysis. *Engineering Geology*, 294: 106372. DOI: <https://doi.org/10.1016/j.enggeo.2021.106372>.
- Li, M., Zhang, L., Shi, X., Liao, M. & Yang, M. (2019). Monitoring active motion of the Guobu landslide near the Laxiwa Hydropower Station in China by time-series point-like targets offset tracking. *Remote Sensing of Environment*, 221: 80–93. DOI: <https://doi.org/10.1016/J.RSE.2018.11.006>.
- Maraun, D., Knevels, R., Mishra, A. N., Truhetz, H., Bevacqua, E., Proske, H., Zappa, G., Brenning, A., Petschko, H., Schaffer, A., Leopold, P. & Puxley, B.L. (2022). A severe landslide event in the Alpine foreland under possible future climate and land-use changes. *Communications Earth & Environment*, 3(1): 87. DOI: <https://doi.org/10.1038/s43247-022-00408-7>.
- Nikolakopoulos, K. G., Kyriou, A., Koukouvelas, I. K., Tomaras, N. & Lyros, E. (2023). UAV, GNSS, and InSAR Data Analyses for Landslide Monitoring in a Mountainous Village in Western Greece. *Remote Sensing*, 15(11): 2870. DOI: <https://doi.org/10.3390/RS15112870>.
- Raspini, F., Bianchini, S., Ciampalini, A., Del Soldato, M., Montalti, R., Solari, L., Tofani, V. & Casagli, N. (2019). Persistent Scatterers continuous streaming for landslide monitoring and mapping: the case of the Tuscany region (Italy). *Landslides*, 16(10): 2033–2044. DOI: <https://doi.org/10.1007/S10346-019-01249-W/FIGURES/7>.
- Refice, A., Spalluto, L., Bovenga, F., Fiore, A., Miccoli, M.N., Muzzicato, P., Nitti, D.O., Nutricato, R. & Pasquariello, G. (2019). Integration of persistent scatterer interferometry and ground data for landslide monitoring: the Pianello landslide (Bovino, Southern Italy). *Landslides*, 16(3): 447–468. DOI: <https://doi.org/10.1007/S10346-018-01124-0/FIGURES/16>.
- Scaioni, M., Longoni, L., Melillo, V. & Papini, M. (2014). Remote Sensing for Landslide Investigations: An Overview of Recent Achievements and Perspectives. *Remote Sensing*, 6(10): 9600–9652. DOI: <https://doi.org/10.3390/RS6109600>.
- Schuster, R.L. (1996). Socioeconomic significance of landslides. *Landslides: Investigation and mitigation*, 247: 12–35.
- Solari, L., Raspini, F., Del Soldato, M., Bianchini, S., Ciampalini, A., Ferrigno, F., Tucci, S. & Casagli, N. (2018). Satellite radar data for back-analyzing a landslide event: the Ponzano (Central Italy) case study. *Landslides*, 15(4): 773–782. DOI: <https://doi.org/10.1007/s10346-018-0952-x>.
- Strozzi, T., Luckman, A., Murray, T., Wegmüller, U. & Werner, C.L. (2002). Glacier motion estimation using SAR offset-tracking procedures. *IEEE Transactions on Geoscience and Remote Sensing*, 40(11): 2384–2391. DOI: <https://doi.org/10.1109/TGRS.2002.805079>.
- Tarquini, S., Vinci, S., Favalli, M., Doumaz, F., Fornaciai, A. & Nannipieri, L. (2012). Release of a 10-m-resolution DEM for the Italian territory: Comparison with global-coverage DEMs and anaglyph-mode exploration via the web. *Computers & Geosciences*, 38(1): 168–170. DOI: <https://doi.org/10.1016/J.CAGEO.2011.04.018>.
- Wang, C., Ge, D., Zhang, G., Zhu, W., Xiong, S., Liu, Y., Yang, H., Wang, S., Xu, L. & Peng, J. (2022). Monitoring and Stability Analysis of the Deformation in the Woda Landslide Area in Tibet, China by the DS-InSAR Method. *Remote Sensing*, 14(3): 532. DOI: <https://doi.org/10.3390/RS14030532>.
- Wang, C., Mao, X. & Wang, Q. (2016). Landslide Displacement Monitoring by a Fully Polarimetric SAR Offset Tracking Method. *Remote Sensing* 8(8): 624. DOI: <https://doi.org/10.3390/RS8080624>.
- Wasowski, J. & Bovenga, F. (2014). Investigating landslides and unstable slopes with satellite Multi Temporal Interferometry: Current issues and future perspectives. *Engineering Geology*, 174: 103–138. DOI: <https://doi.org/10.1016/J.ENGEO.2014.03.003>.
- Wegmüller, U., Werner, C., Strozzi, T. & Wiessman, A. (2002). Automated and Precise Image Registration Procedures. *Analysis of Multi-Temporal Remote Sensing Images*, 37–49. DOI: https://doi.org/10.1142/9789812777249_0002.
- Zhao, C. & Lu, Z. (2018). Remote Sensing of Landslides—A Review. *Remote Sensing*, 10(2): 279. DOI: <https://doi.org/10.3390/RS10020279>.





Investigation of machine learning algorithms to determine glaciers displacements

Magdalena Łucka

Faculty of Geo-Data Science, Geodesy and Environmental Engineering, AGH University of Krakow, Cracow, Poland

ARTICLE INFO

Keywords:

Glacier monitoring
Machine learning
Convolutional neural networks
SAR data
Velocity estimation

ABSTRACT

Ice velocity changes in polar regions reflects the response of glacial areas to climate change progression. Its monitoring improves our understanding of the complexity of processes that affect this part of the world. Existing methods have some limitations like a need for extensive parametrization or adjustment of specific software to only one type of input data. Despite the rapid development of artificial intelligence, the fusion of satellite radar images and machine learning methods is still not thoroughly investigated topic. This study evaluates potential of using machine learning models and Sentinel-1 images for purposes of ice velocity determination. This approach is examined with two testing datasets and one real-world case study. The testing datasets contain original image and its manually shifted version to evaluate effectiveness and accuracy of proposed methodology. The real-world case study is Dagaard-Jensen glacier in eastern Greenland and its results are compared with the traditional remote sensing technique such as an offset-tracking algorithm. This research tested various data augmentation techniques and neural network architectures to find optimal solution that could serve as an alternative approach to deliver horizontal displacement information. The testing datasets showed that obtaining 1-pixel accuracy is possible with the proposed approach. Moreover, in real world conditions, the proposed methodology allowed for obtaining satisfactory results, showing also current limitations of presented approach related mainly to lack of distinguishing features in the main glacier flow.

1. Introduction

The Global Climate Observing System (GCOS) identifies ice velocity as one of 55 Essential Climate Variables (ECV) (World Meteorological Organization (WMO) et al., 2022), highlighting the need for improved methods for its observation. Ice velocity is constantly monitored, particularly in polar regions, and is one of the indicators of current climate change progression, as it is also one of the components that are necessary to estimate mass balance. The importance of high-quality velocity information delivered by earth observation (EO) products in the context of the accuracy of mass balance estimation was already noticed in previous studies (Han and Lee, 2015; Li et al., 2016; Rignot et al., 2008; Shen et al., 2018). Velocity changes might deliver information about the general condition of the glacier and processes that occur beneath the surface. Speedup periods can be associated with glacier retreat or increased basal melting, which leads to friction reduction, which may also be connected to glacier thinning (Joughin et al., 2021; King et al., 2020). Ice velocity measurements could then improve glacier modelling, leading to a better understanding of their impact on

This article is part of a special issue entitled: Earth Observation of the Cryosphere published in Remote Sensing Applications: Society and Environment.

E-mail address: magdalena.lucka@agh.edu.pl.

<https://doi.org/10.1016/j.rsase.2025.101476>

Received 6 November 2024; Received in revised form 19 January 2025; Accepted 25 January 2025

Available online 31 January 2025

2352-9385/© 2025 The Author. Published by Elsevier B.V. This is an open access article under the CC BY license (<http://creativecommons.org/licenses/by/4.0/>).

climate change, including sea-level rise. Moreover, changing ice dynamics reflect how climate change affects the polar regions. This variable can be delivered in a variety of ways, but remote sensing techniques, particularly satellite data, are most commonly used to provide timely, accurate, and global datasets.

Ice velocity can be determined using either active or passive satellite sensors. There are numerous studies demonstrating the feasibility of measuring this ECV using optical, hyperspectral, radar, or combined datasets in various parts of the world (Dirscherl et al., 2020; Joughin et al., 2017; R. Li et al., 2022; Mouginot et al., 2017; Solgaard et al., 2021; Vijay et al., 2019). In the Arctic and Antarctica, considering the polar night phenomenon and significant cloudiness, SAR data can be used to provide full-year observations of areas that are critical for climate change monitoring. Differential Interferometry (DInSAR) is used to measure ice velocity for slow-moving glaciers, while offset-based algorithms are used for faster-flowing glaciers (Joughin, 2002). The DInSAR technique is commonly used in areas such as Svalbard (Eldhuset et al., 2003; Nela et al., 2022; Perski and Jania, 2004; Wangenstein et al., 2005), Himalaya (Kumar et al., 2011, 2023; Nela et al., 2018), Baffin Island (Samsonov, 2019), or Tibetan Plateau (Liu et al., 2016). The combination of both methods delivers a full displacement field by merging results for areas with different ice flow dynamics (Feng et al., 2023; Lin et al., 2022; Luckman et al., 2007; Sánchez-Gómez et al., 2017). Offset-based techniques, which are also called in the literature as feature tracking (Van Wyk De Vries and Wickert, 2021; Zheng et al., 2023), pixel tracking (Jawak et al., 2018), speckle tracking (Joughin, 2002) or template matching (Altena and Käb, 2020), can be applied to both optical and SAR datasets. Focusing on active satellites, two main groups in the offset-based algorithms can be distinguished: intensity tracking (Li et al., 2014), and coherence tracking (Strozzi et al., 2002). The feature tracking algorithms rely on very distinct features that are observed on the surface and can then be easily identified on a pair or stack of images, such as crevasses, moraines, or any other spatial patterns that can be distinguished in images. In the intensity tracking algorithms, the amplitude of the radar signal is used to find a cross-correlation peak between image pairs. For the coherence tracking, small image patches are subtracted from SLC (Single Look Complex) images, and interferograms with various offsets are generated. Then, for each interferogram, the coherence is estimated, and the maximum coherence values point out areas with the highest similarity (Strozzi et al., 2002).

Even though there are numerous methods for velocity estimation, they have some drawbacks and limitations. They require a wide range of parameters that need to be set up to produce reliable results. The parametrization varies depending on the used software and algorithm implementation. However, the input parameters may include such values as searching window size, grid density, over-sampling factor, cross-correlation threshold, interpolation method for correlation peak and for outlier filling, or maximum velocity. The variety of those parameters shows that for different software, sensor types, their spatial resolution, and study areas, there is a large number of parameters that should be optimized. Successful optimisation depends on users knowledge of the algorithm, sensor, and specific study area, which might lead to time-consuming calculations. Parameter space is thus wide and hard to explore for various study areas (Zheng et al., 2023) and the machine-learning (ML) approach might improve ice velocity estimations in this aspect. Moreover, offset-based methods usually apply smoothing of the results, which eliminates all potential outliers. The smoothing might occur in the filtration phase, when noises are reduced on displacement maps by applying various filtration methods. Moreover, some points during processing are classified as outliers due to low cross-correlation values or exceeded maximum expected speed. In such areas, the gaps are usually interpolated based on the neighbouring offsets. Even though such a procedure might provide satisfactory results for most areas, in some cases when the local spatial anomaly is observed, the information about non-linear flow might be lost. Removing such areas or smoothening the results might thus affect the interpretation of ice dynamics, as those areas may be particularly important in providing information about subsurface processes or objects on the glacier surface that disrupt the linear flow of the glacier's tongue.

At the same time, despite the current rapid development of artificial intelligence (AI), there are only a few studies attempting to address this research problem using ML techniques. Current development of ML models is focused more on optical data, and the SAR community is lacking benchmark datasets, and there are still considerably fewer AI models developed for radar datasets than for the optical ones (Zhu et al., 2020). Most of the ML applications related to SAR data are focused on terrain classification (Kussul et al., 2017; Lv et al., 2015), object detection like ships (Jianwei Li et al., 2022; Li et al., 2023; Yasir et al., 2022) or landslides (Ghorbanzadeh et al., 2019; Mohan et al., 2021; Nava et al., 2022), data fusion (Adrian et al., 2021; Li et al., 2022; Schmitt et al., 2018), or despeckling (Fracastoro et al., 2021; Lattari et al., 2019; Ma et al., 2020; Mullissa et al., 2022). Amongst ML applications related to displacement monitoring, current studies focus strongly on such aspects as InSAR displacement time-series prediction (Cieřlik and Milczarek, 2022; Fiorentini et al., 2020; Shami et al., 2024), and detection of movement or vulnerable zones (Breneman and Barnhart, 2021; Confuorto et al., 2022; Mirmazloumi et al., 2022; Tiwari and Shirzaei, 2024). Nevertheless, those studies focus primarily on vertical or LOS (Line Of Sight) movements. Detection of horizontal movements and determining the displacement value via ML models is still not a thoroughly investigated topic. The problem of finding offsets between image pairs was tackled so far by researchers using such techniques as optical flow or various deep learning networks. One of these approaches uses optical flow, which is widely used in different disciplines for motion tracking between images or video frames. This approach was adopted for glacier velocity estimation to retrieve a very dense displacement field by Altena and Käb (2017); Lenzano et al. (2018) and Vogel et al. (2012). However, those studies used optical imagery for purposes of glacier monitoring and SAR dataset were not included in the analysis. Another approach was presented by Shen et al. (2022), where a deep matching network with sister network having shared parameters was used. This type of Siamese network can determine whether image patches are similar or not, and then calculate the offset between them. However, the study is also limited in spatial extent, and no tests were performed on Greenland glaciers. Additionally, the authors highlighted that the best results were retrieved only for high-resolution SAR datasets. A similar problem was also tackled by Kim et al. (2025). The authors developed a new model named CC-ResSiamNet, which aims to find corresponding areas in input images. The model is capable of detecting not only glacier velocity but also horizontal displacement caused by volcanos or earthquakes. Nevertheless, the proposed model requires processing of the initial offset field to train the network, and the presented study aims to work only on coregistered SAR

intensity images without further processing. Considering that only a few studies exist in the area of using ML models for horizontal displacement determination and other deep learning architectures and methods were not thoroughly tested for this application, additional investigation is needed. Given the foregoing, the purpose of this study is to investigate the feasibility of monitoring glacier flow velocities using SAR data and a convolutional neural network (CNN). The CNN's ability to recognise patterns can provide an alternative, novel solution for detecting offsets between coregistered images, delivering the corresponding areas as an output of a network. This study evaluates such an approach using two synthetic datasets and one real-world case study involving the Greenland glacier. It demonstrates how Sentinel-1 (S-1) data can be combined with a developed CNN architecture to produce velocity maps of glaciers. The results are also compared to the traditional offset-tracking (OT) method to determine the effectiveness and accuracy of the proposed approach.

2. Dataset

The ML-based approach for horizontal displacement determination was evaluated on two synthetic datasets (subsection 2.1) and one real-world dataset (subsection 2.2). In the synthetic datasets, the pre- and post-movement images were identical, but they were manually shifted by a defined vector. It ensures that the visual pattern on both images is the same, without external noises and reflectance differences due to e.g., atmospheric disturbances. They represent homogeneous displacement over a whole image with a known value, which enables evaluation of the method's accuracy and usefulness of the proposed approach. The real-world datasets consist of three radar image pairs of the same glacier collected on different dates. Thus, the input images might differ due to weather conditions of glacier surface deformation. Moreover, the estimated velocity field is unknown and needs to be evaluated with an external dataset processed with a traditional remote sensing approach. For the real-world case study, additional post-processing steps are also required, such as masking water bodies, recalculating pixel offsets into metric values based on pixel size, and final velocity estimation.

2.1. Testing datasets

In order to validate the proposed algorithm and assess its accuracy, two test datasets were prepared. Each dataset consists of a pair of images: (1) the original image and (2) the shifted image by a user-defined vector in pixels. The method concept is based on finding corresponding areas on both images by searching similar patterns between smaller image patches. The tests were carried out on the random cat image and on the part of Synthetic Aperture Radar (SAR) acquisition from S-1 satellite (background images in Figs. 5A and 6A). The aim of using example image as one of the datasets was to check the versatility of the method and to facilitate a visual assessment of its performance. Interpretation of such image is much easier and more unambiguous compared to SAR image. It allows for identification of strengths and limitations of the algorithm. The satellite image test from the second dataset aims to verify if the




Fig. 1. Location of area of interest: (a) extent of S-1 images used in the study with Greenland in the background, and (b) area of analysis at the background of natural colour composition from Sentinel-2 satellite.

developed tool works effectively in case of noisier data, with lower resolution and only one spectral canal. The testing image covers the area of the Daugaard-Jensen glacier, which is located in eastern Greenland (Fig. 1). For these purposes, the Ground Range Detected (GRD) product was used, which delivers near-square pixel images. In further analyses, only the amplitude layer with horizontal (HH) polarization was used, as it is characterised by a higher backscatter coefficient than the cross-polarized layer (VH).

2.2. Real-world case study

The utility of the developed method was also tested in real-world conditions over the Daugaard-Jensen glacier (Fig. 1). It is a large outlet glacier and one of the fastest-flowing in the eastern part of Greenland. Daugaard Jensen is also a marine-terminating glacier that flows into the Norvestfjord. It covers approx. 4% of the Greenland ice sheet, and it is stable in terms of mass balance or velocity changes (Bevan et al., 2012; Mouginot et al., 2019). The velocities along the glaciers might vary from 3.0 to 11.0 m/day.

In order to determine glacier's displacement, the GRD products from the S-1 mission were used with a 12-day temporal baseline. They were acquired in Interferometric Wide (IW) mode with the details shown in Table 1. In further analysis, the amplitude layer in horizontal (HH) polarization is utilised.

3. Methods

The development of a new algorithm for glacier displacement monitoring was divided into several stages from data preparation to final model validation, which are presented in Fig. 2. Each of the processing stages is described in detail in the specific subsections. The general workflow begins with the data preprocessing stage, which is described in subsection 3.1. and consists of DEM-based coregistration of SAR images, data sampling and augmentation techniques, and processing parameter determination. In the next step, preprocessed images serve as an input for ML model estimation, which delivers information about corresponding patches between two images. The process of model development and tested parameters is described in subsection 3.2. In subsection 3.3, the results obtained with use of ML techniques are postprocessed in order to analyse the highest quality of data and to produce displacement and velocity maps. In order to validate the proposed algorithm, the reference velocity dataset is calculated with the OT method in subsection 3.4, and its detailed comparison with ML values is discussed in section 5.

3.1. Data preparation and augmentation

Before the ML model was built, the training datasets were created. One full dataset, which may be used for displacement monitoring, consists of the primary image ("reference image" further in the text) and the image acquired later at any time interval (referenced further in the text as "secondary image"). For real-world case study, the input dataset consisting two radar acquisition was firstly coregistered using Digital Elevation Model (DEM) to ensure correct position of both images in space. In order to create a proper dataset, the reference image is divided into smaller image patches with the size of 100x100 pxl. In the next processing steps, those patches will be searched at the secondary image. The secondary image is divided into similar image patches, ensuring a higher density of samples in areas where potential movement can occur. For these purposes, the coordinates of the middle image patch from the reference image are extracted, and the searching radius and sampling density are determined. At the secondary image, the corresponding coordinates are searched, and the division into patches is done in the specified step size until it reaches the maximum searching radius. Each of the new image patches is a separate class in the ML model. All those processing steps are repeated for each image patch created from the reference image. At this stage, each classification class comprises only one image; thus, to apply the ML model correctly, further extension of the training dataset was required. Augmentation of dataset was done by applying rotation, resizing with the determined buffer, and filtering of collected samples with such filters as blur, contour, detail, edge enhance, emboss, find edges, sharpen, and smooth. Rotation and resizing parameters might be modified at the point of dataset building. In the described cases, the rotation was applied in the range of $\pm 15^\circ$ with a 5° step and resizing in the range of ± 2 pxl. The purpose of applied modifications and their parameters is not only to expand the dataset but also to reflect changes that might occur at the testing site, such as stretching or compression of the glacier's surface or rotation due to a change in flow direction.

3.2. Machine-learning model estimation

Datasets created according to the procedure described in section 3.1. Were used as input into the developed ML model. In the

Table 1
Technical parameters of used acquisitions of S-1 mission.

Date	Temporal baseline [days]	Pixel spacing: range x azimuth [m]	Polarization	Path	Frame	Orbit type
2024/02/03	12	10.08 x 10.27	HH + HV	170	354	descending
2024/02/15	12	10.08 x 9.62	HH + HV	170	354	descending
2024/02/15	12	10.08 x 9.62	HH + HV	170	354	descending
2024/02/27	12	10.08 x 9.62	HH + HV	170	354	descending
2024/02/27	12	10.08 x 9.62	HH + HV	170	354	descending
2024/03/10	12	10.08 x 9.62	HH + HV	170	354	descending




Fig. 2. General workflow presenting applied processing steps and data flows.

proposed method, in order to determine horizontal movements, it is necessary to find patches covering the same area on reference and secondary images. After finding corresponding areas, the X,Y coordinates of the centres of both image patches are extracted. It provides information about the location of those smaller patches on the background of a whole image. The difference between the X and Y coordinates of patches in reference and secondary images delivers information about pixel offset along both axes. This pixel offset describes area movement in the time between image acquisitions. Choosing the image patches covering the same area is tackled as a classification problem. The created ML model takes an input sample from the reference image and, as the output, returns the class with the most similar patch from the secondary image. To solve this problem, the CNN was used, which, due to in-depth analysis of the image features in the subsequent network layers, can precisely point out areas with the highest visual similarity.

In order to find appropriate CNN, several tests were performed. Firstly, few architectures were tested: self-developed simple CNNs, LeNet (LeCun et al., 1998), AlexNet (Krizhevsky et al., 2012) and VGG16 (Simonyan and Zisserman, 2014). They were used to generate the velocity and flow direction maps in glacier areas. The visual inspection of general movement direction and magnitude showed the most promising results for the AlexNet architecture. At this point, it was assumed that the glacier tongue flows linearly into the bay with increasing velocity towards the terminus, and areas outside the tongue should represent no movement or relatively small values. Self-developed CNN architectures were not able to properly distinguish image patches, resulting in a messy vector field, which did not represent the natural glacier movement; thus they were removed from analyses. LeNet and AlexNet showed the most similar results; however, AlexNet was more stable over the next iteration. The VGG16 architecture was not further investigated due to the high time and computational costs. In the following steps, several parameters were tested to establish the most suitable values for the study. In terms of optimisers, the two most popular ones were tested: SGD (Stochastic Gradient Descent) and Adam (Adaptive Moment Estimation). As the activation functions, ReLU (rectified linear unit) and tanh (hyperbolic tangent) functions were investigated. Moreover, the learning rate was changed in the range from 0.0005 to 0.01 and the number of epochs from 35 to 200. In order to decide which parameter set is the most suitable, the in-depth analysis was carried out in three zones of glacier images. The first image patch represented a relatively stable area, the second one was located on a main glacier tongue where significant velocities are obtained, and the

third one was located in an area with a small expected velocity. For each of these patches, the following parameters were analysed: accuracy of the prediction, probability of the output patch, loss function, and heatmap of probabilities returned by an ML model for a selected image sample. The final model was aimed to maximise the accuracy and probability and minimise the loss function. The probability map should strictly highlight one area of high probabilities, where the ground truth is located. Maps with significant probability dispersion were assessed as ambiguous results. Moreover, for each parameter set, the whole displacement map was created, and its reliability in terms of movement direction and values was also assessed.

After described testing, the final model was based on the AlexNet architecture with slight modifications. The architecture consists of 5 convolution layers, 3 max-pooling layers, 5 normalised layers, 1 dropout layer, and 2 fully connected layers (Fig. 3). The 'ReLU' activation function was used in the learning process and Adam optimiser, as other configurations provided more distributed probabilities in final results, and in challenging areas the model did not converge. The learning rate was set to 0.001, as it ensured the balance between processing time and model accuracy. The number of epochs was set to 100, as it was observed that the results were not improving with an increased number of iterations, and the best weights were saved during the learning process. The input to the designed CNN is a single image patch with the 100x100 pxl size from the reference image, and as the output, the probabilities are assigned to each class, representing patches from the secondary image. The class with the highest probability is selected as a corresponding one to the input of CNN. In the last step, the differences between the coordinates of the centre of both image patches in the radar system coordinates are used to determine displacement in range and azimuth directions expressed in pixels. Described tests showed that for patches with clearly distinguishing features, almost all sets of parameters delivered satisfactory results. Nevertheless, for image patches near glacier terminus, where the cracks occur and the calving process takes place, finding the corresponding patches remains a significant challenge.

3.3. Filtration and post-processing

The last step of data processing aims to ensure high quality of data and filter outliers that may disturb the analysed displacement field. The filtering process is divided into four stages related to: (1) assessing reliability of the classes returned by the ML model; (2) removing areas of ice-melange; (3) filtering data with the lowest quality; and (4) recalculating offsets in pixels into metric values based on pixel spacing (Fig. 4). Firstly, the probability distribution returned as the output of the ML model is analysed. It allows to determine the level of confidence of the output class with the highest probability value. To test the reliability of the output highest probability value, the mean probability (μ) amongst all output classes and its standard deviation (σ) are calculated. When the analysed probability value exceeds the range of $\mu \pm 3\sigma$, it is considered significantly higher than probabilities assigned to other output classes. Therefore, image patches returned with a probability higher than $\mu + 3\sigma$ remain in the steps of further analysis. Values that do not meet this requirement are rejected as unreliable, as they reflect a very large and uniform probability dispersion between classes and thus an unsatisfactory CNN efficiency for a given part of the image. The second stage of filtering is related to glacier areas and removing ice-mélange or water areas from analysis. The area of interest (AOI) is divided into two classes: 0 - land, 1 - sea-ice/water. It allows to separate glacier parts that float in the bay and do not represent the main glacier flow dynamics. Masking of those areas was performed via visual inspection of SAR acquisitions. In the last step of the post-processing, the probability distribution in a whole area of interest is investigated. In order to remove image patches with the lowest probability, the values across the whole area were analysed, and the threshold value was set to the level of 5%. Image patches with probabilities below this threshold are removed from the analysis of the displacement field. The threshold value was selected in order to keep the balance between the relatively large number of samples and the reduction of patches with high uncertainty. In the last step, the remained offsets in range and azimuth directions are recalculated into metric values, considering the terrain pixel size along both image axes. On the basis of the obtained values, the maximum displacement is calculated as a resultant of range and azimuth offsets. Then mean velocities are determined as maximum displacement divided by temporal baseline between both images. Such an approach to data analysis allows for movement direction assessment and the creation of vector displacement maps.




Fig. 3. Scheme of the designed architecture of CNN.




Fig. 4. Post-processing workflow.




Fig. 5. Results for testing dataset 1: (A) direction of the offset estimated by CNN, (B) maximum probability from ML model, (C) detected offset along X axis, (D) detected offset along Y axis.

3.4. Reference data: offset-tracking

Validation of the results obtained by the proposed method was performed by comparison with displacement maps produced with the offset-tracking (OT) technique. The calculations were performed in the Gamma Software (Werner et al., 2005) based on satellite radar images described in Table 1. This method allows for the identification of corresponding areas between amplitude images using cross-correlation values. It is widely used in glacier areas but also for monitoring landslides (Cai et al., 2017; Jia et al., 2020), or even mining areas (Huang et al., 2020; Zhao et al., 2021). At the stage of image registration, high-resolution Copernicus DEM was used with a spatial resolution of 30 m. For OT method implementation, SLC products with original resolution were used. The registration window size was set to 256 x 64 pxl in range and azimuth directions, respectively. To remove areas of low signal quality, final displacement values were masked with the cross-correlation values of minimum 0,2. Obtained displacement maps were used to check the quality of




Fig. 6. Results for testing dataset 2: (A) direction of the offset, (B) maximum probability from ML model, (C) detected offset along X axis, (D) detected offset along Y axis.

displacement delivered by the CNN model and for purposes of analysis of potential anomalies in glacier flow. Moreover, it helped to map areas of low signal quality, which might affect the CNN results as well.

4. Results

The ML results are presented separately for synthetic datasets in [subsection 4.1](#) and for real-world scenario in [subsection 4.2](#). The first part focuses on pixel offsets amongst X and Y axes and probabilities of determined values. The real-world dataset part is focused more on actual metric velocities and the direction of the main flow. The correctness of synthetic dataset results is checked with the defined vector values, and for the glacier case study, the accuracy is determined by comparison with external data in the discussion section.

4.1. Testing datasets

The first of the testing datasets, which represents a photo of the cat, was manually shifted by a vector determined in a raster coordinates: $[dX, dY] = [-10 \text{ pxl}, -3 \text{ pxl}]$. Using the designed CNN, the overall direction of the movement ([Fig. 5A](#)) and its probabilities ([Fig. 5B](#)) were assessed. Moreover, the offsets along X ([Fig. 5C](#)) and Y ([Fig. 5D](#)) axes were determined. Due to the fact that reference and secondary images had the same sizes but were shifted, there is no full overlap between those samples, thus not all image patches are visible in both images. Therefore, it is impossible to detect movements in those areas by a developed algorithm. Considering above, firstly, the results from the first row and column of the image were removed, as in these parts of the image there is no overlap between samples. Analysis of the offsets distribution along both axes ([Fig. 5C](#) and [D](#)) revealed that approx. 81% of all image patches were correctly identified between images. Moreover, around 6% of image patches have been indicated with the error of $\pm 1 \text{ pxl}$. The vector map created based on dX and dY offsets reveals that the general direction of the movement is properly detected. A single vector shows the direction that does not match the overall pattern. The highest number of outliers is noticed in the upper right corner. In the central part, almost all image patches were correctly identified. The probability map ([Fig. 5B](#)), representing the confidence level of each vector, presents that nearly 80% of image patches have the probability higher than 0.90. All of those samples are also correct matches. Lower probability values were obtained for areas with incorrect classifications. The results presented indicate that the developed methodology has the potential to be applied in detecting corresponding areas, as evidenced by the high percentage of tiles correctly identified. In-depth analysis of patches, which were classified with an error higher than 1 pxl, shows that the most challenging areas are those with a homogenous background and without specific visible features. This problem is especially visible in the upper right corner of the image, where six adjacent patches have similar backgrounds and no distinguishing objects. In the central and lower parts of the image, plenty of characteristic features are visible, such as a moustache, striped fur, and eye pupil, which makes the detection of similar areas easier. Thus, in these regions, correct results were obtained with high probability values. The offsets in this part of the image were detected within 1 pxl accuracy.

In the next step, the proposed methodology was tested on image of the Dagaard-Jensen glacier from 03.02.2024, collected as a GRD product, which was shifted 3 pixels along X axis and 8 pixels along Y axis in raster coordinates. The aim of this test was to check the effectiveness of the algorithm if the input dataset consists of only one amplitude layer with single polarization (HH), instead of a traditional 3-channel RGB image. The analysis was carried out for an area of $1450 \times 1950 \text{ pxl}$, which was divided into 266 smaller image patches for which the offsets were detected. After filtering the results with the approach presented in [subsection 3.3.](#), 19 patches were removed due to low quality. Amongst 247 patches, which were further evaluated, 223 matches were ideal matches, which stand for 90.3% of all answers. Incorrect matches were observed for 24 patches. Twenty of them were classified as $\pm 1 \text{ pxl}$ error, which represent 8.1% of all samples. The last 4 patches were classified as errors exceeding 1 pxl, representing 1.6% of all indications. The directions of detected offsets ([Fig. 6A](#)) are consistent with the vector defined at the beginning. Directions that significantly differ from the expected vector are observed for 2 of 247 analysed image patches. Analysis of the offsets detected along X ([Fig. 6C](#)) and Y ([Fig. 6D](#)) axes revealed that more correct matches were registered along Y than X axis. The probability map ([Fig. 6B](#)) indicated that for most of the tiles, the confidence of the output values is higher than 80%. Outside the main glacier flow, probability values were at a very high level, ranging from 95% to 100%. The lowest probabilities are observed on the main axis of the glacier, where image patches do not have distinguishing features that might help the pattern recognition process. Results obtained using the SAR testing dataset indicate that the proposed methodology works correctly and might be useful for displacement monitoring. In the next stage of the research, the designed methodology was tested in real-world application over the same glacier area.

4.2. Real-world case study: Dagaard-Jensen glacier

For the Dagaard-Jensen glacier case study, S-1 GRD products with a 12-day temporal baseline were used as an input dataset to generate three velocity maps. Those acquisitions were firstly stacked in remote sensing software using DEM-assisted coregistration to ensure the correct position of both images. The coregistered amplitude images with horizontal polarization served as reference and secondary images in the proposed method. As a result of the CNN-based calculations, displacement information along the X-axis and along the Y-axis expressed in pixels was obtained. These values were converted into average velocities for each tile based on the time baseline ([Fig. 7B](#), [D](#), [7F](#)), and the direction of displacement was determined ([Fig. 7A](#), [C](#), [7E](#)).

Both the vector and velocity maps for all three periods indicate a very clear division into relatively stable regions and fast-moving glacier tongue, where significant movements up to 12–13 m/day are observed. Outside the main glacier flow, detected values do not exceed 1 m/day, and the vectors show no movement or negligible values. Average velocities in main glacier flow range between 6 and




Fig. 7. Results of CNN-based calculation for Dagaard-Jensen glacier for 3 periods: (A,C,E) vector maps of glaciers' movements direction, and (B,D, F) average velocities [m/day].

8 m/day. The upper left corner of the analysed region lacks data because it is an area of floating ice, which is not a subject to this research. In the main glacier flow area, most of the tiles with low probabilities were observed, and they were removed from the analysis at the stage of data filtration. Very low probabilities suggest that the complexity of the problem is too high for implemented CNN and might be caused by, e.g., significant deformation of the surface layer of the glacier in time. It leads to changes in properties and the general look of the ice; thus, the radar signal reflectance differs significantly between subsequent SAR acquisitions. The effects of this problem are mainly noticed as lack of data in the upper part of the image, close to the terminus, where the material is cracked and deformed and numerous fissures appear, which significantly reduced the quality of the results obtained with the CNN. On all three velocity maps, some single peaks are observed in the background with velocities reaching 3 m/day, which might be considered as potential unfiltered outliers. For all periods, the maximum velocities are located near the terminus and usually do not exceed the value of 11 m/day. Throughout the main glacier flow, the average values remain similar over time; however, some patches with very low values (e.g., 3 m/day) are observed, and some further outlier detection should be considered. The vector maps presented in Fig. 7A, C, 7E generally show a proper glacier flow, assuming that the natural glacier movement should occur in the direction of a bay. Maps presented in Fig. 7C and E shows reliable values and directions even near the glacier terminus, where the highest speed is observed and material forms into linear shapes. However, some vectors showing non-linear flow appear, especially in the middle and lower part of the glacier, which might be considered as an error.

The calculated velocity maps were based on four consecutive SAR images; thus, the glacier speed should not vary significantly in time. Therefore, the stability of the method was assessed by differencing delivered velocity maps and analysing changes between them.




Fig. 8. Differences between consecutive velocity maps: spatial distribution (A, B), and histograms of those differences with mean values and standard deviation (C, D).

The discrepancies between periods were presented in the form of maps showing spatial distribution (Fig. 8A and B) and histograms with mean difference and standard deviation (Fig. 8C and D). Presented maps show that outside of glacier tongue the method is consistent, and most of the tiles have differences close to 0 or within the range of ± 1 m/day. Higher variability is observed over the main flow, especially in the lower part of Daugaard-Jensen located more inland. Probably these areas lack distinguishing features that make the problem of finding corresponding matches more challenging. Nevertheless, the statistical analysis of discrepancies between following periods in the form of a histogram shows that the mean difference in velocity is -0.4 m/day between the first and second periods and $+0.1$ m/day between the second and third maps. Standard deviation in both cases was established at the level of ± 2.2 m/day and ± 1.7 m/day, which corresponds to the accuracy of the method analysed further in section 5.

5. Discussion

Accuracy and quality of the results obtained by the ML approach were assessed by comparison with velocities retrieved with the OT method for the same SAR images that were used in CNN calculations. For the Daugaard-Jensen glacier, the velocities varied from 0 to 10 m/day (Fig. 9A, B, 9C) for all three periods. After masking floating ice areas, maximum velocity near glacier terminus reaches approx. 9 m/day. Outside the glaciers tongue, a stable area with velocities of almost 0 m/day is observed. Along the main glacier flow, most of the areas reach velocities in the range of 5–8 m/day. In order to unambiguously compare velocities obtained with different




Fig. 9. Velocities of the Daugaard-Jensen glacier calculated by the OT algorithm (A–C), differences between OT and CNN velocities (D–F) and histograms of those differences (G–I).

methods, values from the OT methods were averaged in 100 x 100 pxl boxes in areas corresponding to image patches from the CNN-based method. Velocities from both methods were compared for each tile and for each period independently. The maps (Fig. 9D, E, 9F) and histograms (Fig. 9G, H, 9I) of differences between average velocities from both methods were created for each period. Analysing the spatial distribution of discrepancies between both methods, it is visible that over stable regions, both techniques are consistent. There are only single points where the movement was detected, despite the expected velocity being close to 0 m/day. The largest deviations are located in the central part of the glacial tongue and at the boundaries of detectable movements. In the central part, it is likely that the near-surface ice layer has been significantly deformed during the analysed interval due to rapid glacial movement or melting of the top layer. The observed top layer of the glacier by satellite has probably changed strongly, thus preventing the proposed method from working correctly. The edge of the glacier is a particularly difficult area for correct detection. Because rectangular sections of the images are analysed, the part of the tile located in the glacier's main flow is displaced, while the rest of the tile is stable. Classifying such a region remains a challenge for this method, as some of the pixels show zero displacement and some show several-pixel displacements. Due to the difficulty of such regions, the differences in average velocities with respect to the OT method can be significant. The OT method largely averages and smooths the acquired results; hence, any outliers can be removed and supplemented with averages during processing, which also affects the quality of the compared results. The calculated statistics show that the mean difference between both methods for analysed periods is 1.0 ± 2 m/day, 0.7 ± 1.7 m/day, and 0.8 ± 1.6 m/day. The differences detected for all three periods shows similar accuracy of the proposed method compared to the OT results. The CNN-based method tends to overestimate the glacier velocity. It is worth noting that considering the pixel size of used images and their time baseline, an error in offset estimation equal to 1 pxl corresponds to a velocity change of 0.8 m/day. It can be concluded that the mean discrepancy between the OT method and the proposed algorithm is approximately 1 pxl. Considering the scale of the movements reaching 10 m/day near the terminus, the achieved accuracy is satisfactory. It is worth noticing on the histogram plots that the number of samples where the differences are almost equal to 0 is represented by the highest bar. Further analysis reveals that for analysed three periods 49%, 62% and 58% of all samples are within the range of -0.8 to 0.8 m/day error, which corresponds to maximum of ± 1 pxl mismatch. Moreover, with a ± 2 pxl accuracy, which stands for ± 1.6 m/day error, 76%, 79% and 77% of all samples were classified for subsequent periods. Considering the errors calculated during the comparison with the OT method and the stability analysis from section 4.2, it can be concluded that the accuracy of the CNN-based method in this case is ± 2 pxl. The same variability was observed compared to traditional remote sensing methods and between the following velocity maps delivered by the proposed method.

The proposed method, despite using well-known data augmentation techniques and CNN architecture, presents for the first time how they can be used for glacier motion monitoring. The literature lacks studies where only SAR datasets are used for ML-derived displacement monitoring. Presented results confirm the possibility of using CNN and SAR data for delivering reliable velocity maps. Moreover, results from the testing dataset highlight that the proposed workflow is correct and might achieve high accuracies. There are only a few studies applying ML tools to provide glacier velocity fields. One of the approaches is based on velocimetry, which is widely used for various flow visualisations and speed analyses. It can also be used for glacier motion estimation and driven by deep learning algorithms (Thomole et al., 2023; Van Wyk De Vries and Wickert, 2021). However, those studies are limited to the usage of optical imagery, especially Sentinel-2 data, and none of them utilise SAR datasets. Another approach utilising computer vision algorithms is related to optical flow application, which was also investigated in terms of suitability for horizontal displacement determination (Altena and Käbb, 2017; Lenzano et al., 2018; Vogel et al., 2012b), but these studies also investigated mainly usage of optical datasets. Fu et al. (2022) applied the optical flow methodology on SAR data on one of the mountain glaciers; nevertheless, the study did not utilise the deep learning methods. The most similar problem of using SAR and ML algorithms for velocity mapping was tackled by Kim et al. (2025) and Shen et al. (2022). The former approach utilised a combination of residual and Siamese networks for horizontal displacement estimation in various areas, based on SAR datasets. The presented approach, nevertheless, is based on learning on initial offset fields, which require additional processing, and this study's aim was to utilise only coregistered intensity images without additional preprocessing steps. The study presented by Shen et al. (2022) uses the Siamese network approach for delivering velocity maps of two glaciers in Alaska and the Himalayas. The authors used high-resolution SAR imagery and S-1 data to provide a velocity field in these two cases. The authors highlighted the problem of SAR data quality and resolution influencing velocity maps. Thus, this study aims to focus on open-source S-1 satellite and finding alternative CNN-based solutions to deliver reliable velocity maps despite medium resolution. Presented research shows a workflow for satisfactory displacement map delivery with ML tools and focuses on method development and first real-world results. Applying ML techniques for glacier velocity estimation might be particularly useful in terms of the limited number of parameters that need to be determined compared to traditional offset-based algorithms. Moreover, successful deployment of such a model might deliver results for any sensor type and could also be applied not only to SAR datasets but also to optical or multispectral. The testing datasets show that the method can be easily generalised and used not only for glacier displacement measurement but also for measuring offsets between any input images. However, the real-world study shows that the present approach has some drawbacks, and several areas remain a challenge. Despite applying post-processing filtering based on results significance, some outliers are still visible that make glacier flow not linear. Especially in areas with no distinguishing features or where the glacier's surface is changing significantly, the algorithm struggles to find corresponding areas. Moreover, the current approach to find the same areas on both images is time-consuming and requires resolving the multi-class classification problem multiple times. Thus, the optimisation of this part or adjusting the current approach to speed up calculations is needed to make the tool more efficient.

Considering the above, other ML algorithms and data augmentation techniques should be further investigated to obtain high-quality and reliable results. In terms of ML improvements, the alternative approach for finding corresponding patches should be considered. One of them could rely on Siamese neural network (Bromley et al., 1993) architecture that would be beneficial in terms of reducing time efficiency and improving the generalisability of the model. With such architecture, the final output of the model can

determine whether the image patches are similar or not, instead of performing multi-class classification as presented in this study. Special attention should also be paid to existing image matching tools that are used in different fields of study and can be tested for adjusting the usage of satellite images in glacier studies. Such tools, like LightGlue (Local Feature Matching at Light Speed) (Lindenberg et al., 2023), are usually faster and already optimized, thus they should be further investigated whether they can be applied into remote sensing tasks. In terms of data augmentation and preparation improvements, their might be added colour space transformation, like adjusting brightness, contrast or changing colour scale. These additional operations might improve ability of the model to distinguish visual pattern on image patches. Furthermore, different input layers and multi-layer input images should be also considered and tested. Presented results are based only on one amplitude layer with horizontal polarization (HH), but layers with other polarizations might be also tested. Moreover, different colour scales for intensity layer representation might be used, as well as amplitudes ratios to create false colour composite RGB images. Despite described limitations, this study presents the alternative approach for glacier velocity mapping with ML models, which shows the promising results on both testing and real-world datasets.

6. Conclusions

This study investigated the potential of using CNN to detect the horizontal movement of the glacier between two SAR acquisitions. The tests were carried out on two test datasets, which were manually shifted, including a cat photo and a single SAR amplitude image, and in real-world conditions on the Dugaard-Jensen glacier in eastern Greenland. This research reveals that such a combination of machine learning algorithms and EO data might deliver reliable results in detecting offsets between two images and was not investigated earlier in the studies. The testing datasets show that with distinguishing features visible in input images, the offset detection can be done ideally. In areas where the surface is more complex and ambiguous, the errors increase, but only a few percent of all image patches are matched incorrectly. Most of the incorrect matches are within ± 1 pxl error. Moreover, the real-world case study from Greenland glaciers shows that compared to the OT algorithm, the mean deviation between those two methods is ranges from 1.0 ± 2.0 m/day to 0.8 ± 1.6 m/day. Considering the pixel size of the input image of 10 m, the 1 pxl mismatch corresponds to approx. 0.8 m/day error, which means that the overall accuracy of the algorithm is at the level of ± 2 pixels. The in-depth analysis shows that the movement area is well-detected and stable zones are mostly correctly detected. More significant discrepancies are observed over the main flow of the glacier. Lower accuracies are probably caused by an ambiguous and changing amplitude image of surface layers, which might change in time due to speed changes and the thawing-freezing cycle of ice.

The presented study shows a huge potential for detection of horizontal movements based on EO products and machine learning algorithms. Such a solution might serve as an alternative source of displacement and velocity maps, which gives the opportunity to, e. g., spot and confirm areas with unusual behaviour like rapid changes that might be indicators of ongoing subsurface processes. Moreover, successful deployment of such an algorithm might improve delivering horizontal displacement maps using not only SAR images as input but also optical or multispectral satellite and aerial images, relaying on machine learning ability to recognise similar signal patterns. Nevertheless, the presented workflow should be further improved in terms of optimisation and velocity map quality. The results from the Dugaard-Jensen glacier show that the delivered displacement field lacks linearity and some outliers are still visible. Lack of distinguishing features in the main flow of the glacier lowers the accuracy and performance of the presented approach, thus further investigation in this field is needed.

Ethical statement

The author declare that all ethical practices have been followed in relation to the development, writing, and publication of the article.

Declaration of competing interest

The authors declare that they have no known competing financial interests or personal relationships that could have appeared to influence the work reported in this paper.

Acknowledgment

The presented investigation is part of the research project “Novel view on the study of glacier kinematics in the context of global climate change” funded by the National Science Centre of Poland under Preludium-21 Grant No. 2022/45/N/ST10/02382.

Data availability

Data will be made available on request.

References

- Adrian, J., Sagan, V., Maimaitijiang, M., 2021. Sentinel SAR-optical fusion for crop type mapping using deep learning and Google Earth Engine. *ISPRS J. Photogrammetry Remote Sens.* 175, 215–235. <https://doi.org/10.1016/j.isprsjprs.2021.02.018>.

- Altena, B., Kääb, A., 2020. Ensemble matching of repeat satellite images applied to measure fast-changing ice flow, verified with mountain climber trajectories on Khumbu icefall, Mount Everest. *J. Glaciol.* 66, 905–915. <https://doi.org/10.1017/JOG.2020.66>.
- Altena, B., Kääb, A., 2017. Weekly glacier flow estimation from dense satellite time series using adapted optical flow technology. *Front. Earth Sci.* 5, 254101. <https://doi.org/10.3389/FEART.2017.00053/BIBTEX>.
- Bevan, S.L., Murray, T., Luckman, A.J., Hanna, E., Huybrechts, P., 2012. Stable dynamics in a Greenland tidewater glacier over 26 years despite reported thinning. *Ann. Glaciol.* 53, 241–248. <https://doi.org/10.3189/2102AoG60A076>.
- Brengman, C.M.J., Barnhart, W.D., 2021. Identification of surface deformation in InSAR using machine learning. *Geochemistry, Geophysics, Geosystems* 22, e2020GC009204. <https://doi.org/10.1029/2020GC009204>.
- Bromley, J., Bentz, J.W., Bottou, L., Guyon, I., LeCun, Y., Moore, C., Sackinger, E., Shah, R., 1993. Signature verification using a “Siamese” time delay neural network, pp. 669–688. <https://doi.org/10.1142/S0218001493000339>.
- Cai, J., Wang, C., Mao, X., Wang, Q., Lu, Z., Li, Z., Tomas, R., Gloaguen, R., 2017. An adaptive offset tracking method with SAR images for landslide displacement monitoring. *Rem. Sens.* 9, 830. <https://doi.org/10.3390/RS9080830>, 2017, Vol. 9, Page 830.
- Cieslik, K., Milczarek, W., 2022. Application of machine learning in forecasting the impact of mining deformation: a case study of underground copper mines in Poland. *Rem. Sens.* 14, 4755. <https://doi.org/10.3390/RS14194755>, 2022, Vol. 14, Page 4755.
- Confuorto, P., Medici, C., Bianchini, S., Del Soldato, M., Rosi, A., Segoni, S., Casagli, N., 2022. Machine learning for defining the probability of sentinel-1 based deformation trend changes occurrence. *Rem. Sens.* 14, 1748. <https://doi.org/10.3390/RS14071748>, 2022, Vol. 14, Page 1748.
- Dirscherl, M., Dietz, A.J., Dech, S., Kuenzer, C., 2020. Remote sensing of ice motion in Antarctica – a review. *Remote Sens. Environ.* 237, 111595. <https://doi.org/10.1016/J.RSE.2019.111595>.
- Eldhuset, K., Andersen, P.H., Hauge, S., Isaksson, E., Weydahl, D.J., 2003. ERS tandem InSAR processing for DEM generation, glacier motion estimation and coherence analysis on Svalbard. *Int. J. Rem. Sens.* 24, 1415–1437. <https://doi.org/10.1080/01431160210153039>.
- Feng, X., Chen, Z., Li, G., Ju, Q., Yang, Z., Cheng, X., 2023. Improving the capability of D-InSAR combined with offset-tracking for monitoring glacier velocity. *Remote Sens. Environ.* 285, 113394. <https://doi.org/10.1016/J.RSE.2022.113394>.
- Fiorentini, N., Maboudi, M., Leandri, P., Losa, M., Gerke, M., 2020. Surface motion prediction and mapping for road infrastructures management by PS-InSAR measurements and machine learning algorithms. *Rem. Sens.* 12, 3976. <https://doi.org/10.3390/RS12233976>, 2020, Vol. 12, Page 3976.
- Fracastoro, G., Magli, E., Poggi, G., Scarpa, G., Valsesia, D., Verdoliva, L., 2021. Deep learning methods for synthetic aperture radar image despeckling: an overview of trends and perspectives. *IEEE Geosci Remote Sens. Mag.* 9, 29–51. <https://doi.org/10.1109/MGRS.2021.3070956>.
- Fu, Y., Zhang, B., Liu, G., Zhang, R., Liu, Q., Ye, Y., 2022. An optical flow SBAS technique for glacier surface velocity extraction using SAR images. *Geosci. Rem. Sens. Lett.* IEEE 19, <https://doi.org/10.1109/LGRS.2022.3200422>.
- Ghorbanzadeh, O., Blaschke, T., Gholamnia, K., Meena, S.R., Tiede, D., Aryal, J., 2019. Evaluation of different machine learning methods and deep-learning convolutional neural networks for landslide detection. *Rem. Sens.* 11, 196. <https://doi.org/10.3390/RS11020196>, 2019, Vol. 11, Page 196.
- Han, H., Lee, H., 2015. Tide-corrected flow velocity and mass balance of Campbell Glacier Tongue, East Antarctica, derived from interferometric SAR. *Remote Sens. Environ.* 160, 180–192. <https://doi.org/10.1016/J.RSE.2015.01.014>.
- Huang, J., Bai, Y., Lei, S., Deng, K., 2020. Time-series SBAS pixel offset tracking method for monitoring three-dimensional deformation in a mining area. *IEEE Access* 8, 118787–118798. <https://doi.org/10.1109/ACCESS.2020.3004460>.
- Jawak, S.D., Upadhyay, A., Pandit, P.H., Luis, A.J., 2018. Changes on velocity of Fisher glacier, east Antarctica using pixel tracking method. *Int. Arch. Photogram. Rem. Sens. Spatial Inf. Sci.* XLII-5, 537–541. <https://doi.org/10.5194/ISPRS-ARCHIVES-XLII-5-537-2018>.
- Jia, H., Wang, Y., Ge, D., Deng, Y., Wang, R., 2020. Improved offset tracking for predisaster deformation monitoring of the 2018 Jinsha River landslide (Tibet, China). *Remote Sens. Environ.* 247, 111899. <https://doi.org/10.1016/J.RSE.2020.111899>.
- Joughin, I., 2002. Ice-sheet velocity mapping: a combined interferometric and speckle-tracking approach. *Ann. Glaciol.* <https://doi.org/10.3189/172756402781817978>.
- Joughin, I., Shapero, D., Smith, B., Dutrieux, P., Barham, M., 2021. Ice-shelf retreat drives recent Pine Island Glacier speedup. *Sci. Adv.* 7, 3080–3091. <https://doi.org/10.1126/SCIADV.ABG3080>.
- Joughin, I., Smith, B.E., Howat, I.M., 2017. A complete map of Greenland ice velocity derived from satellite data collected over 20 years. <https://doi.org/10.1017/jog.2017.73>.
- Kim, J., Jung, H.S., Lu, Z., 2025. Ground surface displacement measurement from SAR imagery using deep learning. *Remote Sens. Environ.* 318, 114577. <https://doi.org/10.1016/J.RSE.2024.114577>.
- King, M.D., Howat, I.M., Candela, S.G., Noh, M.J., Jeong, S., Noël, B.P.Y., Van Den Broeke, M.R., Wouters, B., Negrete, A., 2020. Dynamic ice loss from the Greenland Ice Sheet driven by sustained glacier retreat. *Communications Earth & Environment*. <https://doi.org/10.1038/s43247-020-0001-2>.
- Krizhevsky, A., Sutskever, I., Hinton, G.E., 2012. ImageNet classification with deep convolutional neural networks. *Adv. Neural Inf. Process. Syst.* 25.
- Kumar, V., Høgda, K.A., Larsen, Y., 2023. Across-track and multi-aperture InSAR for 3-D Glacier velocity estimation of the Siachen glacier. *Rem. Sens.* 15, 4794. <https://doi.org/10.3390/RS15194794>, 2023, Vol. 15, Page 4794.
- Kumar, V., Venkataramana, G., Høgda, K.A., 2011. Glacier surface velocity estimation using SAR interferometry technique applying ascending and descending passes in Himalayas. *Int. J. Appl. Earth Obs. Geoinf.* 13, 545–551. <https://doi.org/10.1016/J.JAG.2011.02.004>.
- Kussul, N., Lavreniuk, M., Skakun, S., Shelestov, A., 2017. Deep learning classification of land cover and crop types using remote sensing data. *Geosci. Rem. Sens. Lett.* IEEE 14, 778–782. <https://doi.org/10.1109/LGRS.2017.2681128>.
- Lattari, F., Leon, B.G., Asaro, F., Rucci, A., Prati, C., Matteucci, M., 2019. Deep learning for SAR image despeckling. *Rem. Sens.* 11, 1532. <https://doi.org/10.3390/RS11131532>, 2019, Vol. 11, Page 1532.
- LeCun, Y., Bottou, L., Bengio, Y., Haffner, P., 1998. Gradient-based learning applied to document recognition. *Proc. IEEE* 86, 2278–2323. <https://doi.org/10.1109/5.726791>.
- Lenzano, M.G., Lannutti, E., Toth, C., Rivera, A., Lenzano, L., 2018. Detecting Glacier surface motion by optical flow. *Photogramm. Eng. Rem. Sens.* 84, 33–42. <https://doi.org/10.14358/PERS.84.1.33>.
- Li, J., Chen, J., Cheng, P., Yu, Z., Yu, L., Chi, C., 2023. A survey on deep-learning-based real-time SAR ship detection. *IEEE J. Sel. Top. Appl. Earth Obs. Rem. Sens.* 16, 3218–3247. <https://doi.org/10.1109/JSTARS.2023.3244616>.
- Li, J., Hong, D., Gao, L., Yao, J., Zheng, K., Zhang, B., Chanussot, J., 2022. Deep learning in multimodal remote sensing data fusion: a comprehensive review. *Int. J. Appl. Earth Obs. Geoinf.* 112, 102926. <https://doi.org/10.1016/J.JAG.2022.102926>.
- Li, J., Li, Z.W., Ding, X.L., Wang, Q.J., Zhu, J.J., Wang, C.C., 2014. Investigating mountain glacier motion with the method of SAR intensity-tracking: removal of topographic effects and analysis of the dynamic patterns. *Earth Sci. Rev.* 138, 179–195. <https://doi.org/10.1016/J.EARSCIREV.2014.08.016>.
- Li, Jianwei, Xu, C., Su, H., Gao, L., Wang, T., 2022. Deep learning for SAR ship detection: past, present and future. *Rem. Sens.* 14, 2712. <https://doi.org/10.3390/RS14112712>, 2022, Vol. 14, Page 2712.
- Li, R., Li, G., Feng, T., Shen, Q., Qiao, G., Ye, Z., Xia, M., 2022. A review of Antarctic ice velocity products and methods based on optical remote sensing satellite images. *Acta Geod. Cartogr. Sinica* 51, 953. <https://doi.org/10.11947/J.AGCS.2022.20220168>.
- Li, X., Rignot, E., Mouginot, J., Scheuchl, B., 2016. Ice flow dynamics and mass loss of Totten Glacier, East Antarctica, from 1989 to 2015. *Geophys. Res. Lett.* 43, 6366–6373. <https://doi.org/10.1002/2016GL069173>.
- Lin, K., Qiao, G., Zhang, L., Popov, S., 2022. Extraction of ice flow velocity by combination of DinSAR and offset tracking methods for pine glacier, West Antarctica. *Int. Arch. Photogram. Rem. Sens. Spatial Inf. Sci.* XLIII-B3–2022, 765–770. <https://doi.org/10.5194/ISPRS-ARCHIVES-XLIII-B3-2022-765-2022>.
- Lindenberger, P., Sarlin, P.-E., Pollefeys, M., 2023. LightGlue: local feature matching at Light speed. *ICCV*.
- Liu, G., Guo, H., Yue, H., Perski, Z., Yan, S., Song, R., Fan, J., Ruan, Z., 2016. Modified four-pass differential SAR interferometry for estimating mountain glacier surface velocity fields. *Remote Sensing Letters* 7, 1–10. https://doi.org/10.1080/2150704X.2015.1094588/ASSET/AFB89524-B24D-41A1-B994-D17B8293E180/ASSETS/IMAGES/TRSL_A_1094588_F0003_C.JPG.

- Luckman, A., Quincey, D., Bevan, S., 2007. The potential of satellite radar interferometry and feature tracking for monitoring flow rates of Himalayan glaciers. *Remote Sens. Environ.* 111, 172–181. <https://doi.org/10.1016/J.RSE.2007.05.019>.
- Lv, Q., Dou, Y., Niu, X., Xu, Jiaqing, Xu, Jinbo, Xia, F., 2015. Urban land use and land cover classification using remotely sensed SAR data through deep belief networks. *J. Sens.* 2015, 538063. <https://doi.org/10.1155/2015/538063>.
- Ma, X., Wang, C., Yin, Z., Wu, P., 2020. SAR image despeckling by noisy reference-based deep learning method. *IEEE Trans. Geosci. Rem. Sens.* 58, 8807–8818. <https://doi.org/10.1109/TGRS.2020.2990978>.
- Mirmazloumi, S.M., Gambin, A.F., Palamà, R., Crosetto, M., Wassie, Y., Navarro, J.A., Barra, A., Monserrat, O., 2022. Supervised machine learning algorithms for ground motion time series classification from InSAR data. *Rem. Sens.* 14, 3821. <https://doi.org/10.3390/RS14153821>, 2022, Vol. 14, Page 3821.
- Mohan, A., Singh, A.K., Kumar, B., Dwivedi, R., 2021. Review on remote sensing methods for landslide detection using machine and deep learning. *Transactions on Emerging Telecommunications Technologies* 32, e3998. <https://doi.org/10.1002/ETT.3998>.
- Mouginot, J., Rignot, E., Björk, A.A., van den Broeke, M., Millan, R., Morlighem, M., Noël, B., Scheuchl, B., Wood, M., 2019. Forty-six years of Greenland Ice Sheet mass balance from 1972 to 2018. *Proc. Natl. Acad. Sci. U. S. A.* 116, 9239–9244. <https://doi.org/10.1073/PNAS.1904242116/~DCSUPPLEMENTAL>.
- Mouginot, J., Rignot, E., Scheuchl, B., Millan, R., 2017. Comprehensive annual ice sheet velocity mapping using landsat-8, Sentinel-1, and RADARSAT-2 data. *Rem. Sens.* 9, 364. <https://doi.org/10.3390/RS9040364>, 2017, Vol. 9, Page 364.
- Mullissa, A.G., Marcos, D., Tuia, D., Herold, M., Reiche, J., 2022. DeSpeckNet: generalizing deep learning-based SAR image despeckling. *IEEE Trans. Geosci. Rem. Sens.* 60. <https://doi.org/10.1109/TGRS.2020.3042694>.
- Nava, L., Monserrat, O., Catani, F., 2022. Improving landslide detection on SAR data through deep learning. *Geosci. Rem. Sens. Lett. IEEE* 19. <https://doi.org/10.1109/LGRS.2021.3127073>.
- Nela, B.R., Singh, G., Kulkarni, A.V., Malik, K., 2018. Optimum conditions for differential SAR interferometry technique to estimate Himalayan Glacier Velocity. *ISPRS annals of the photogrammetry. Remote Sensing and Spatial Information Sciences IV–5*, 137–140. <https://doi.org/10.5194/ISPRS-ANNALS-IV-5-137-2018>.
- Nela, B.R., Singh, G., Mohanty, S., Rajat, Arigony-Neto, J., Glazovsky, A.F., 2022. Retrieval of Svalbard ice flow velocities using Sentinel 1A/1B three-pass Differential SAR Interferometry. *Geocarto Int.* 37, 10130–10151. <https://doi.org/10.1080/10106049.2022.2032391>.
- Perski, Z., Jania, J., 2004. SAR-Interferometric flow velocities of two tidewater glaciers in NW Spitsbergen: methods and results. *Proceedings of the FRINGE 2003 Workshop*.
- Rignot, E., Bamber, J.L., Van Den Broeke, M.R., Davis, C., Li, Y., Van De Berg, W.J., Van Meijgaard, E., 2008. Recent Antarctic ice mass loss from radar interferometry and regional climate modelling. *Nat. Geosci.* 1, 106–110. <https://doi.org/10.1038/ngeo102>, 2008 1:2.
- Samsonov, S., 2019. Three-dimensional deformation time series of glacier motion from multiple-aperture DInSAR observation. *J. Geod.* 93, 2651–2660. <https://doi.org/10.1007/s00190-019-01325-y>.
- Sánchez-Gómez, P., Navarro, F.J., Paul, F., Wuite, J., Briggs, K., McNabb, R., Nuth, C., Li, X., Thenkabail, P.S., 2017. Glacier surface velocity retrieval using D-InSAR and offset tracking techniques applied to ascending and descending passes of Sentinel-1 data for southern Ellesmere ice caps. *Canadian Arctic*. <https://doi.org/10.3390/rs9050442>.
- Schmitt, M., Hughes, L.H., Zhu, X.X., 2018. The SEN1-2 dataset for deep learning in SAR-optical data fusion. *ISPRS annals of the photogrammetry. Remote Sensing and Spatial Information Sciences* 4, 141–146. <https://doi.org/10.5194/isprs-annals-IV-1-141-2018>.
- Shami, S., Shahriari, M.A., Nilfouroushan, F., Forghani, N., Salimi, M., Reshadi, M.A.M., 2024. Surface displacement measurement and modeling of the Shah-Gheyb salt dome in southern Iran using InSAR and machine learning techniques. *Int. J. Appl. Earth Obs. Geoinf.* 132, 104016. <https://doi.org/10.1016/J.JAG.2024.104016>.
- Shen, H., Zhou, S., Fang, L., Yang, J., 2022. Glacier motion monitoring using a novel deep matching network with SAR intensity images. *Rem. Sens.* 14, 5128. <https://doi.org/10.3390/RS14205128>, 2022, Vol. 14, Page 5128.
- Shen, Q., Wang, H., Shum, C.K., Jiang, L., Hsu, H.T., Dong, J., 2018. Recent high-resolution Antarctic ice velocity maps reveal increased mass loss in Wilkes Land, East Antarctica OPEN. *Nature Scientific Reports*. <https://doi.org/10.1038/s41598-018-22765-0>.
- Simonyan, K., Zisserman, A., 2014. Very deep convolutional networks for large-scale image recognition. *3rd International Conference on Learning Representations, ICLR 2015 - Conference Track Proceedings*.
- Solgaard, A., Kusk, A., Boncori, J.P.M., Dall, J., Mankoff, K.D., Ahlström, A.P., Andersen, S.B., Citterio, M., Karlsson, N.B., Kjeldsen, K.K., Korsgaard, N.J., Larsen, S.H., Fausto, R.S., 2021. Greenland ice velocity maps from the PROMICE project. *Earth Syst. Sci. Data* 13, 3491–3512. <https://doi.org/10.5194/ESSD-13-3491-2021>.
- Strozzi, T., Luckman, A., Murray, T., Wegmüller, U., Werner, C.L., 2002. Glacier motion estimation using SAR offset-tracking procedures. *IEEE Trans. Geosci. Rem. Sens.* 40, 2384–2391. <https://doi.org/10.1109/TGRS.2002.805079>.
- Tiwari, A., Shirzaei, M., 2024. A novel machine learning and deep learning semi-supervised approach for automatic detection of InSAR-based deformation hotspots. *Int. J. Appl. Earth Obs. Geoinf.* 126, 103611. <https://doi.org/10.1016/J.JAG.2023.103611>.
- Thomole, J.B., Piggott, M.D., Hughes, G.O., 2023. Deep Glacier image velocimetry: mapping glacier velocities from Sentinel-2 imagery with deep learning. In: *NeurIPS 2023 Workshop on Tackling Climate Change with Machine Learning*.
- Van Wyk De Vries, M., Wickert, A.D., 2021. Glacier Image Velocimetry: an open-source toolbox for easy and rapid calculation of high-resolution glacier velocity fields. *Cryosphere* 15, 2115–2132. <https://doi.org/10.5194/TC-15-2115-2021>.
- Vijay, S., Khan, S.A., Kusk, A., Solgaard, A.M., Moon, T., Björk, A.A., 2019. Resolving seasonal ice velocity of 45 Greenlandic glaciers with very high temporal details. *Geophys. Res. Lett.* 46, 1485–1495. <https://doi.org/10.1029/2018GL081503>.
- Vogel, C., Bauder, A., Schindler, K., Sensing, R., Zürich, E., 2012. Optical flow for glacier motion estimation. *ISPRS annals of the photogrammetry. Remote Sensing and Spatial Information Sciences I–3*, 359–364. <https://doi.org/10.5194/ISPRSANNALS-I-3-359-2012>.
- Wangensteen, B., Weydahl, D.J., Hagen, J.O., 2005. Mapping glacier velocities on Svalbard using ERS tandem DInSAR data. *Geografisk Tidsskrift* 59, 276–285. <https://doi.org/10.1080/00291950500375500>.
- Werner, C., Wegmüller, U., Strozzi, T., Wiesmann, A., 2005. Precision estimation of local offsets between pairs of SAR SLCs and detected SAR images. In: *IGARSS Proceedings*. Seoul.
- World Meteorological Organization (WMO), United Nations Environment Programme (UNEP), International Science Council (ISC), Intergovernmental Oceanographic Commission of the United Nations Educational, S. and C.O. (IOC-U), 2022. The 2022 GCOS Implementation Plan. Geneva.
- Yasir, M., Jianhua, W., Mingming, X., Hui, S., Zhe, Z., Shanwei, L., Colak, A.T.I., Hossain, M.S., 2022. Ship detection based on deep learning using SAR imagery: a systematic literature review. *Soft Comput.* 27, 63–84. <https://doi.org/10.1007/S00500-022-07522-W>, 2022 27:1.
- Zhao, G., Wang, L., Deng, K., Wang, M., Xu, Y., Zheng, M., Luo, Q., 2021. An adaptive offset-tracking method based on deformation gradients and image noises for mining deformation monitoring. *Rem. Sens.* 13, 2958. <https://doi.org/10.3390/RS13152958>, 2021, Vol. 13, Page 2958.
- Zheng, W., Bhushan, S., Van Wyk De Vries, M., Kochtitzky, W., Shean, D., Copland, L., Dow, C., Jones-Ivey, R., Pérez, F., 2023. GLAcier Feature Tracking testkit (GLAFT): a statistically and physically based framework for evaluating glacier velocity products derived from optical satellite image feature tracking. *Cryosphere* 17, 4063–4078. <https://doi.org/10.5194/TC-17-4063-2023>.
- Zhu, X.X., Montazeri, S., Ali, M., Hua, Y., Wang, Y., Mou, L., Shi, Y., Xu, F., Bamler, R., 2020. Deep Learning Meets SAR. *ArXiv* 1–26.