

POLITECHNIKA WARSZAWSKA
DYSCYPLINA NAUKOWA
INŻYNIERIA LĄDOWA, GEODEZJA I TRANSPORT
DZIEDZINA NAUK INŻYNIERYJNO-TECHNICZNYCH

Rozprawa doktorska

mgr inż. Viktor Szabó

Analiza możliwości synergii obserwacji teledetekcyjnych
z grawimetrycznymi oraz istotności czynników wpływających na
obserwowane zmiany poziomu wód gruntowych rejestrowanych
przez satelity GRACE i GRACE-FO

Promotor
dr hab. inż. Katarzyna Osińska-Skotak, prof. uczelni

Promotor pomocniczy
dr inż. Tomasz Olszak

WARSZAWA 2024

Streszczenie

Woda, jako jeden z najcenniejszych zasobów naturalnych, jest poddawana stałemu monitorowaniu ze względu na jej kluczową rolę w życiu na Ziemi oraz prognozowanie ekstremalnych zjawisk pogodowych jak susze czy powodzie. Monitoring ten jest integralnym elementem i wpisuje się w podstawowe cele programu GGOS (ang. *Global Geodetic Observing System*). Wielopoziomowość systemu obiegu wody w przyrodzie prowadzi do wielowymiarowej złożoności prowadzenia pomiarów zmienności zawartości wody w glebie. Z tego względu rejestracja tego sygnału z pułapu satelitarnego stanowi znaczące wyzwanie dla badaczy z całego świata.

Praca doktorska skupia się na analizie synergii między danymi uzyskanymi z różnych sensorów grawimetrycznych i teledetekcyjnych w kontekście monitorowania zmian zasobów wodnych na Ziemi określanych jako ΔTWS (ang. *Total Water Storage changes*). Przeprowadzone badania naukowe dotyczą analizy istotności czynników wpływających na rejestrację zmian poziomu wód gruntowych obserwowanych przez satelity grawimetryczne GRACE (ang. *Gravity Recovery And Climate Experiment*) i GRACE-FO (ang. *Grace Follow on*) i zbadania w jakich warunkach możliwe by było synergiczne wykorzystanie obserwacji dostarczanych do modeli hydrologicznych za pomocą satelitarnych sensorów o odmiennej charakterystyce. Kluczowym pytaniem postawionym w pracy jest, czy możliwe jest wykorzystanie informacji zawartych w danych zebranych przez czujniki charakteryzujące się większym szumem i wariancją sygnału, takimi jak dane dotyczące wilgotności gleby (SM, ang. *Soil Moisture*) pochodzące z misji AMSR-E (ang. *Advanced Microwave Scanning Radiometer*), w globalnej analizie zmienności ΔTWS z satelitów GRACE i GRACE-FO. W pracy zdefiniowano także szereg aspektów badawczych, obejmujących m.in. analizę przestrzennych i czasowych zależności pomiędzy danymi teledetekcyjnymi a grawimetrycznymi, ocenę wpływu metody filtracji danych, wykorzystanie technik uczenia maszynowego w rekonstrukcji sygnału oraz wyznaczenie czynników umożliwiających większą zgodność sygnałów z tych dwóch źródeł danych.

Przeprowadzone badania obejmują zarówno analizy regionalne, jak i globalne, co pozwala na pełniejsze zrozumienie dynamiki zmian wód na Ziemi i dostarcza podstaw dla skuteczniejszych działań zarządczych w obszarze monitorowania środowiska naturalnego. Badania wykazały, że satelitarne sensory grawimetryczne są skutecznym narzędziem do analizy ekstremalnych zjawisk klimatycznych, takich jak susze i powodzie, pod warunkiem odpowiedniej filtracji przestrzennej sygnału. Modelowanie lokalnych czynników hydrologicznych oraz antropogenicznych jest kluczowe dla dokładności obserwacji naziemnych i satelitarnych, zwłaszcza w przypadku obserwacji warunków hydrologicznych. Wykorzystanie nowoczesnych technik uczenia maszynowego pozwala na skuteczną rekonstrukcję sygnału ΔTWS na podstawie danych z modeli GLDAS (ang. *Global Land Data Assimilation System*) oraz danych dotyczących SM. Praca stanowi wkład w rozwój naukowego zrozumienia procesów

hydrologicznych na Ziemi oraz wskazuje kierunki dalszych badań w zakresie analizy danych grawimetrycznych i teledetekcyjnych.

słowa kluczowe: grawimetria, teledetekcja, GRACE, AMSR-E, zmiany zasobów wody

Abstract

Water, one of the most valuable natural resources, undergoes constant monitoring due to its crucial role in Earth's life and the forecasting of extreme weather phenomena such as droughts and floods. This monitoring aligns with the fundamental goals of the GGOS (*Global Geodetic Observing System*) program. The multi-level nature of the Earth's water cycle leads to multidimensional complexity in measuring soil water content variability. Consequently, recording this signal from a satellite perspective poses a significant challenge for researchers worldwide.

The doctoral thesis analyzes the synergy between data obtained from various gravimetric and remote sensing sensors in the context of monitoring changes in Earth's water resources, referred to as Total Water Storage (Δ TWS) changes. The scientific research conducted pertains to the analysis of the significance of factors influencing the registration of groundwater level changes recorded by gravimetric satellites GRACE (*Gravity Recovery And Climate Experiment*) and GRACE-FO (*Grace Follow-on*) and the investigation of under what conditions synergistic use of observations delivered to hydrological models via satellite sensors with different characteristics would be possible. A key question posed in the thesis is whether it is possible to utilize information contained in data collected by sensors characterized by higher noise and signal variance, such as soil moisture (SM) data from the AMSR-E mission (*Advanced Microwave Scanning Radiometer*), in a global analysis of Δ TWS variability from GRACE and GRACE-FO satellites. The thesis also defines several research aspects, including the analysis of spatial and temporal dependencies between remote sensing and gravimetric data, assessment of the impact of data filtering methods, utilization of machine learning techniques in signal reconstruction, and determination of factors enabling greater alignment of signals from these two data sources.

The conducted research encompasses regional and global analyses, allowing for a fuller understanding of water dynamics on Earth and providing the basis for more effective environmental monitoring management. The studies have shown that gravimetric satellite sensors are practical tools for analyzing extreme climatic phenomena, such as droughts and floods, provided spatial signal filtering is adequate. Modeling local hydrological and anthropogenic factors is crucial for the accuracy of ground-based and satellite observations, especially regarding hydrological conditions. Modern machine learning techniques enable effective signal reconstruction based on the GLDAS (*Global Land Data Assimilation System*) model and SM data. The thesis contributes to advancing scientific understanding of hydrological processes on Earth and sets directions for further research in gravimetric and remote sensing data analysis.

keywords: gravimetry, remote sensing, GRACE, AMSR-E, water storage changes

Spis treści

1	Forma rozprawy doktorskiej	8
2	Motywacja, cele i hipotezy badawcze	10
3	Wstęp	14
4	Podstawy teoretyczne	17
4.1	Grawimetria satelitarna jako unikalna technika pomiarów zmiany przyspieszenia siły ciężkości związanej ze śledzeniem zmian mas	17
4.2	Zmiany przyspieszenia wynikające ze zmian wilgotności gruntu, wyrażanej jako ΔTWS - opis zjawiska	17
4.3	Grawimetryczne misje satelitarne GRACE i GRACE-FO	18
4.4	Zastosowania satelitarnych danych grawimetrycznych	21
4.5	Charakterystyka pomiarów teledetekcyjnych zorientowanych na badanie zmian wilgotności (AMSR-E)	22
4.6	Wyznaczenie wilgotności gleby wyrażonej jako SM za pomocą mikrofalowych sensorów AMSR-E	24
4.7	Przegląd dotychczasowych badań opublikowanych w literaturze naukowej .	25
5	Metodyka badań	30
5.1	Przetwarzanie danych GRACE oraz GRACE-FO	31
5.2	Przetwarzanie danych AMSR-E	34
5.3	Opis wykorzystanych danych	35
5.4	Normalizacja i skalowanie czasowo-przestrzennych danych dotyczących ΔTWS	38
5.5	Konieczność i sposoby filtracji obserwacji GRACE i GRACE-FO	39
5.6	Metody dekompozycji sygnału LSSA i STL	40
5.7	Określenie metod i kryteriów porównawczych oraz miar jakości pomiędzy analizowanymi zbiorami danych	41
5.8	Transformacje liniowe sygnału ΔTWS za pomocą EOF	45
5.9	Analiza maksymalnej kowariancji	46
5.10	Metody rekonstrukcji sygnału ΔTWS przy użyciu metod bazujących na uczeniu maszynowym	47
6	Syntetyczny opis wyników badań	52
6.1	Publikacja [1]	52
6.2	Publikacja [2]	55
6.3	Publikacja [3]	57

6.4	Publikacja [4]	60
6.5	Publikacja [5]	62
7	Podsumowanie	65
8	Wykaz użytych skrótów i akronimów	69
9	Bibliografia	73
10	Załączniki	94
10.1	Lista załączników	94
10.2	Załączniki	94

1 Forma rozprawy doktorskiej

Niniejsza rozprawa doktorska została przygotowana w formie spójnego tematycznie zbioru pięciu prac opublikowanych w czasopismach naukowych oznaczonych numerami [1-5].

- [1] Kuczynska-Siehien, J., Piretzidis, D., Sideris, M. G., Olszak, T. and Szabó, V. (2019) *'Monitoring of extreme land hydrology events in central Poland using GRACE, land surface models and absolute gravity data'*, Journal of Applied Geodesy, Vol. 13, No. 3, pp.229–243, doi: 10.1515/jag-2019-0003.
100 pkt MEiN; IF: 1.30
- [2] Szabó, V. and Marjańska, D. (2020) *'Accuracy analysis of gravity field changes from GRACE RL06 and RL05 data compared to in situ gravimetric measurements in the context of choosing optimal filtering type'*, Artificial Satellites: Journal of Planetary Geodesy, Vol. 55, No. 3, pp.100–117, doi: 10.2478/arsa-2020-0008.
70 pkt MEiN; IF: 0.90
- [3] Szabó, V. (2023) *'Comparison features importance for temporal and spatial-temporal approaches in GRACE and GRACE-FO signal reconstruction based on GLDAS data'*, International Journal of Hydrology Science and Technology, doi: 10.1504/IJHST.2023.134623
100 pkt MEiN; IF: 1.80
- [4] Szabó, V. and Osińska-Skotak, K. (2023) *'Similarities and differences in the Earth's water variations signal provided by GRACE and AMSR-E observations using Maximum Covariance Analysis at various Land Cover data backgrounds'*, Artificial Satellites: Journal of Planetary Geodesy, Vol. 58, No. 2 - 2023, doi: 10.2478/arsa-2023-0006
70 pkt MEiN; IF: 0.90
- [5] Szabó, V., Osińska-Skotak, K. and Olszak, T. (2024) *'Using machine learning techniques to reconstruct the signal observed by the GRACE mission based on AMSR-E microwave data'*, Miscellanea Geographica - Regional Studies on Development, Vol. 28, No. 2 - 2024, doi: 10.2478/mgrsd-2023-0033
100 pkt MEiN; IF: 0.80

Suma punktów MEiN: 440

Mój udział w poszczególnych publikacjach był następujący:

- [1] Przygotowanie danych z misji GRACE, napisanie skryptu umożliwiającego filtrowanie danych współczynników sferycznych harmonicznych poziomu 2 filtrami nieizotropowymi DDK1-8. Jednostkowy udział: **10%**
- [2] Przygotowanie danych, praca nad koncepcją i metodyką badań, przeprocesowanie i analiza rozwiązań, przegląd literatury, przygotowanie całej treści artykułu w języku polskim. Jednostkowy udział: **80%**
- [3] Przygotowanie koncepcji i metodyki badań, przegląd literatury, napisanie kodu umożliwiającego analizę rozwiązań, opracowanie danych, analiza wyników, ich dyskusja i wnioski. Przygotowanie oryginalnej wersji artykułu i korekta na podstawie otrzymanych recenzji. Jednostkowy udział: **100%**
- [4] Przygotowanie koncepcji i metodyki badań, przegląd literatury, napisanie kodu umożliwiającego analizę rozwiązań, opracowanie danych, analiza wyników, ich dyskusja i wnioski. Przygotowanie oryginalnej wersji artykułu i korekta na podstawie otrzymanych recenzji. Jednostkowy udział: **85%**
- [5] Przygotowanie koncepcji i metodyki badań, przegląd literatury, napisanie kodu umożliwiającego analizę rozwiązań, opracowanie danych, analiza wyników, ich dyskusja i wnioski. Przygotowanie oryginalnej wersji artykułu i korekta na podstawie otrzymanych recenzji. Jednostkowy udział: **80%**

Oświadczenia współautorów publikacji określające indywidualny wkład każdego autora w powstanie poszczególnych publikacji zamieszczono rozdziale (10) w poszczególnych załącznikach.

2 Motywacja, cele i hipotezy badawcze

Globalne pomiary geodezyjne pełnią dwie istotne funkcje w dziedzinie obserwacji Ziemi: dostarczają ram odniesienia niezbędnych do wszystkich obserwacji zależnych od lokalizacji, co stanowi fundament większości obserwacji ziemskich oraz dostarczają obserwacji dotyczących zmieniającego się w czasie kształtu, pola grawitacyjnego i rotacji Ziemi. Ponieważ Ziemia jest ciągle deformowana przez wewnętrzne procesy geodynamiczne oraz przez transport masy i energii w płynnej powłoce astenosfery, zdolność do zrozumienia i modelowania tych procesów niesie znaczące korzyści przy tworzeniu stabilnych rozwiązań i projektowaniu systemów (ITRS, ang. *International Terrestrial Reference System*) i układów (ITRF, ang. *International Terrestrial Reference Frame*) odniesień przestrzennych.

GGOS (ang. *Global Geodetic Observing System*) (Plag et al., 2009, Rothacher et al., 2009) stanowi fundamentalną infrastrukturę dla badań nad dynamicznymi zmianami w obrębie naszej planety oraz dostarcza kluczowe produkty dla zrozumienia procesów związanych z deformacją globalną i wymianą masy zachodzącą w litosferze, hydrosferze, atmosferze i kriosferze. W obliczu coraz potężniejszych skutków zmian pochodzenia zarówno naturalnego jak i antropogenicznego, świadome zarządzanie naszym środowiskiem staje się kluczowym wyzwaniem. W celu zminimalizowania negatywnego wpływu działalności człowieka na ekosystem i równowagę naszej planety oraz zachowania zasobów naturalnych dla przyszłych pokoleń, niezbędne jest pogłębione zrozumienie procesów zachodzących na Ziemi. Wymaga to kompleksowych badań, modelowania, prognozowania oraz podejmowania decyzji politycznych opartych na wszechstronnych obserwacjach systemu Ziemi. Zjawiska takie jak susze, powodzie, trzęsienia ziemi, tsunami czy erupcje wulkanów stanowią jedynie wierzchołek góry lodowej, obrazując niepokojącą dynamikę zmian na Ziemi. Obserwacje te są nie tylko istotne dla naukowego poznania naszej planety, ale również mają fundamentalne znaczenie dla wielu sektorów gospodarki oraz społeczeństwa jako całości. Pomiar zmiennego w czasie kształtu, pola grawitacyjnego i rotacji Ziemi to elementy celów GGOS oraz ich implementacji przy pomocy GEOSS (ang. *Global Earth Observation System of Systems*) (Lautenbacher, 2006). GEOSS to zestaw skoordynowanych, niezależnych systemów pozyskiwania obserwacji, informacji i przetwarzania danych dotyczących Ziemi, które współdziałają i zapewniają dostęp do różnorodnych informacji szerokiego gronu użytkowników zarówno z sektora publicznego, jak i prywatnego. GEOSS łączy te systemy w celu wzmocnienia komplementarności monitorowania stanu Ziemi.

Woda jest jednym z najcenniejszych zasobów naturalnych na Ziemi (De Villiers, 2001, Lvovich, 1979). Stały monitoring tych zasobów, obiegu wody i cyklu hydrologicznego daje niezwykle korzyści w postaci nie tylko zrozumienia procesów zachodzących na naszej planecie, ale również predykcji ekstremalnych zjawisk pogodowych, takich jak susze czy

powodzie. Naukowcy stosują w swoich pracach badawczych dane dotyczące zmian ekwiwalentu wodnego. Badania te znajdują swoje praktyczne zastosowanie w rolnictwie, monitoringu zmian klimatu lub chociażby przewidywaniu katastrof naturalnych (Foroumandi et al., 2023, Hao et al., 2018, Rashid et al., 2020). Wykorzystanie danych z modeli hydrologicznych, danych teledetekcyjnych lub grawimetrycznych na stałe zagościło w dziedzinie badań związanych z klimatem. Ze względu na znaczną liczbę badań, w których przetwarza się, łączy i analizuje dane z sensorów grawimetrycznych w połączeniu z innymi danymi o różnej rozdzielczości czasowo-przestrzennej (Dee et al., 2011, Döll et al., 2014, Eicker et al., 2014, Jackson et al., 1981) motywacją do badań stała się potrzeba przeprowadzenia prac, które pozwoliłyby na określenie przypadków, dla których wymienne wykorzystanie danych wielosensorowych jest możliwe. Tego rodzaju synergiczne użycie danych umożliwiłoby monitorowanie zmian hydrologicznych na powierzchni Ziemi w sposób bardziej operacyjny. Ważnym elementem badań było stwierdzenie czy możliwa jest minimalizacja wpływu błędów spowodowanych sposobem przetwarzania danych lub wpływem elementów środowiskowych, które powodują, że dane pochodzące z różnych czujników opisujące analogiczne zjawiska dają nie koherentne wyniki.

Istotność wyżej wymienionych warunków oraz ich bezpośredni wpływ na klimat i życie ludzi na Ziemi, stanowiły dodatkową motywację do powstania tejże rozprawy doktorskiej.

W pracy postawiono następującą tezę badawczą:

Istnieją uwarunkowania, dla których występuje duża zgodność rejestracji zmian zawartości wód przypowierzchniowych obserwowanych za pomocą mikrofalowych technik teledetekcyjnych w zestawieniu ze zmianami całkowitego ekwiwalentu wodnego obserwowanymi przez satelitarne misje grawimetryczne.

Głównymi celami badawczymi rozprawy były:

- (a) Analiza możliwości synergii obserwacji teledetekcyjnych z grawimetrycznymi pod kątem uzyskania informacji i rozkładu zawartości wody w glebie.
- (b) Analiza istotności czynników wpływających na rejestrację zmian poziomu wód gruntowych rejestrowanych przez satelity GRACE i GRACE-FO.


Zdefiniowano kilka następujących aspektów badawczych:

1. Zbadanie zależności pomiędzy danymi uzyskiwanymi za pomocą sensorów grawimetrycznych dalekiego zasięgu oraz bliskiego (pomiarów satelitarne i naziemne) w kontekście obserwacji ekstremalnych zjawisk pogodowych takich, jak susze czy powodzie. Publikacje [1][2][5]

2. Ocena wpływu metody filtracji danych poziomu 2 wynikających z specyfikacji inklinacji orbity misji GRACE w zależności od rozdzielczości przestrzennej badanych zjawisk geofizycznych w kontekście dokładności obserwowanego zjawiska. Publikacja [1][2]
3. Analiza możliwości łączenia danych z pomiarami/danymi o innym spektrum czasowym i przestrzennym wraz ze wskazaniem istotności poszczególnych parametrów fizycznych zawartych w modelach hydrologicznych przy użyciu współczesnych technik rekonstrukcji sygnału. Publikacje [3][4][5]
4. Zbadanie przestrzennych i czasowych zależności pomiędzy danymi z sensorów grawimetrycznych i teledetekcyjnych w kontekście badanie różnic w wyznaczaniu wilgotności potrzebnej do modelowania zasobów wód podziemnych poprzez odjęcie wierzchniej warstwy wodnej. Publikacje [4][5]
5. Wyznaczenie czynników pozwalające na uchwycenie większej zgodności sygnałów teledetekcyjnych (o dużej rozdzielczości czasowo-przestrzennej) z satelitarnymi pomiarami grawimetrycznymi (o słabszej rozdzielczości czasowo-przestrzennej) w celu wyodrębnienia obszarów i warunków, dla których możliwe jest dokładne interpolowanie obserwacji GRACE oraz takich warunków, dla których należy opracować bardziej wyrafinowane modele zależności. Publikacje [3][4][5]

Publikacje [1][2] dotyczą regionalnych badań na szeregu obserwacyjnym grawimetrycznych pomiarów absolutnych w Obserwatorium Astronomiczno-Geodezyjnym w Józefosławiu. Prace [3][4] obejmują analizy globalne dla obserwacji i modeli globalnych. Podzielenie badań na dwa podejścia (lokalne i globalne) umożliwia uzyskanie pełnego obrazu i poprawnego wnioskowania w zakresie przetwarzania danych grawimetrycznych z misji GRACE i GRACE-FO. Publikacja [5] podsumowuje prace z zakresu badań regionalnych i globalnych. Najważniejsze wyniki z przeprowadzonych badań zostały przedstawione w rozdziale (6).

Schemat ilustrujący przebieg prac badawczych oraz relacje między publikacjami tworzącymi cykl przedstawiono na rysunku (1).



Rysunek 1: Uproszczony schemat prac badawczych oraz relacje między publikacjami tworzącymi cykl. Źródło: Opracowanie własne

3 Wstęp

Grawimetria satelitarna jest unikalną techniką pomiarów zmiany przyspieszenia siły ciężkości. Umożliwia obserwacje transportu mas i procesów zachodzących na Ziemi w globalnej skali. Jedną z takich misji satelitarnych jest misja GRACE (ang. *Gravity Recovery And Climate Experiment*) (Tapley et al., 2004b, Wahr et al., 1998). Znalazła ona swoje zastosowania w hydrologii, badaniach atmosfery, zmian klimatycznych, monitoringu geozagrożeń, zmian poziomu mórz, oceanów oraz skorupy ziemskiej. Na przestrzeni ostatnich 15 lat pogłębiła wiedzę ludzkości na temat naszej planety i zmian zachodzących na jej powierzchni. Niezliczone korzyści płynące z prowadzenia satelitarnych obserwacji grawimetrycznych doprowadziły do wysłania kolejnej misji GRACE-FO (ang. *Grace Follow on*) (Flechtner et al., 2016), która będzie kontynuować pozyskiwanie danych, umożliwiając dalsze pogłębianie wiedzy dotyczącej naszej planety. Jednak metodyka opracowania satelitarnych danych grawimetrycznych oraz sposób korzystania z tych danych w zależności od przeprowadzanego eksperymentu naukowego są kluczowe, aby móc wyciągać poprawne wnioski i doskonalić prognozy dotyczące zmian klimatu (Pail et al., 2015, Tapley et al., 2019). Problematyka związana z koniecznością filtracji zaszumionych danych GRACE, powstałych na skutek okołobiegunowej inklinacji orbity, jest niezwykle istotna ze względu na stosunkowo niewielką rozdzielczość przestrzenną obserwacji (Swenson and Wahr, 2006). Zbyt intensywne wygładzanie sygnału prowadzi do utraty istotnych informacji geofizycznych, które w zależności o konkretnych warunków i kryteriów badań mogą być pożądane w danym eksperymencie naukowym. Istnieje znaczny potencjał w wykorzystaniu łączenia danych GRACE z innymi obserwacjami z sensorów zarówno o większej częstotliwości obserwacji, jak i wyższej rozdzielczości przestrzennej. Kluczowe jest jednak zbadanie i wyznaczanie warunków sprzyjających odzyskiwaniu jak największej części informacji zawartej w obserwowanym sygnale grawitacyjnym.

Zmiany w dystrybucji masy na Ziemi wynikają w znacznym stopniu ze zmian całkowitego ekwiwalentu wody wyrażanej jako ΔTWS (ang. *Total Water Storage changes*). Misja GRACE umożliwia obserwację zmian dystrybucji wody z około miesięczną częstotliwością pomiarów, zwykle przedstawianej jako łączna miesięczna średnia zmiana magazynowanej wody poprzez usunięcie średniej długoterminowej podzielonej przez odchylenie standardowe, znane jako anomalia TWS (TWSA). TWSA odpowiada sumie wszystkich zasobów wód powierzchniowych nad i pod powierzchnią, w tym wilgoci w glebie, wód powierzchniowych, jezior, rzek i wód gruntowych. Jest to z perspektywy hydrologicznej ważny parametr i element badań naukowców szczególnie na terenach niedostępnych lub nie objętych monitoringiem hydrologicznym (Kusche et al., 2016, Rodell et al., 2018). Badanie zbieżności obserwacji hydrologicznych z różnych zbiorów danych i warunków, przy których są uzyskiwane pozwala na lepsze zrozumienie procesów zachodzących na Ziemi

i podejmowanie decyzji na obszarach dotkniętych takimi wydarzeniami jak chociażby susze czy powodzie (Chen et al., 2007, Liu et al., 2020, Zhao et al., 2017a).

Prawie roczna przerwa między funkcjonowaniem GRACE i GRACE-FO zrodziła pytania o przyszłość obserwacji GRACE-FO, a co za tym idzie zrozumienie ciągłych zmian klimatu. Wykazywane przez naukowców korzyści płynące z monitoringu globalnych procesów zmian zarówno naturalnych, jak i tych spowodowanych czynnikami antropogenicznymi stawiają cel ciągłości pomiarów na wysokim miejscu listy priorytetów i założeń GGOS. Fakt ten przyczynia się do konieczności prowadzenia badań naukowych mających na celu stworzenie najwyższej jakości rozwiązań umożliwiających dostarczanie danych oraz modelowanie zmian w obrębie ziemskiego pola siły ciężkości (Kusche et al., 2016, Rodell et al., 2018). Do tego zadania konieczne jest połączenie pomiarów różnych sensorów, a także wielowymiarowa analiza związana z czynnikami wpływającymi bezpośrednio na zmiany obserwowane w polu siły ciężkości Ziemi.

Wilgotność gleby wyrażona jako SM (ang. *Soil Moisture*) to istotna zmienna hydrologicznego stanu gleby, będąca głównym składnikiem ΔTWS (Robinson et al., 2008). Aktywne i pasywne obserwacje mikrofalowe umożliwiają analizę wilgotności gleby na skalę globalną i regionalną (Babaeian et al., 2019). Ze względu na ograniczenia związane z rozdzielczością czasowo-przestrzenną danych GRACE istotnym czynnikiem przy analizie możliwości synergii danych z innymi sensorami o wyższej częstotliwości pomiarów i rozdzielczości przestrzennej jest zachowanie istotności statycznej dla podtrzymania wszelkich wyprowadzonych wniosków z badań naukowych (Ioannidis, 2005). Z tego powodu wybór sensorów podyktowany jest długością i ciągłością prowadzonych obserwacji, tak by możliwie jak najlepiej pokrywał część wspólną z okresem pomiarów prowadzonych przez misje GRACE i GRACE-FO. Jednym z kluczowych sensorów teledetekcyjnych dostarczających danych o wilgotności gleby była misja AMSR-E (ang. *Advanced Microwave Scanning Radiometer*). AMSR-E to zaawansowany skanujący radiometr mikrofalowy, który stanowi element systemu obserwacyjnego Ziemi (Njoku et al., 2005). Urządzenie to zostało zaprojektowane do pomiaru elektromagnetycznego promieniowania mikrofalowego w celu uzyskania informacji o parametrach związanych z cyklem wodnym i klimatem. AMSR-E zbiera dane dotyczące wilgotności gleby, opadów atmosferycznych, pokrywy śnieżnej i innych istotnych aspektów związanych z obiegiem wody w środowisku. Wykorzystuje on mikrofałe, które są emitowane, absorbowane i rozpraszane przez różne formy wody, takie jak chmury, opady atmosferyczne i pokrywa śnieżna. Dzięki tym pomiarom, AMSR-E dostarcza wartościowe dane naukowe, które są istotne dla analizy i monitorowania zmian w środowisku naturalnym na naszej planecie. Sensor ten dostarczał dane obejmujące okres od czerwca 2002 r. do początku października 2011 r., pokrywając w ten sposób znaczącą część okresu obserwacji z misji GRACE. Doczekał się też swojej kontynuacji w postaci mi-

sji AMSR-2 oraz AMSR-3, będących częścią planowanej na marzec 2024 r. misji GOSAT-GW (ang. *Global Observing SATellite for Greenhouse gases and Water cycle*), tym samym dając najdłuższy spójny szereg obserwacji SM ([Kasahara et al., 2020](#)).

Synergia obserwacji teledetekcyjnych z grawimetrycznymi pod kątem uzyskania informacji o rozkładzie zawartości wody w glebie ma znaczny potencjał badawczy. Osiąganie lepszych wyników poprzez połączenie lub współdziałanie różnych zbiorów danych w celu dokładniejszego oszacowania tempa ubytku wody w danym obszarze, miejsc zagrożonych suszą i predykcja zachodzących zmian, stanowi ważny element badań naukowych dotyczący bezpośrednio wszystkich ludzi zamieszkujących Ziemię. Wykorzystanie różnorodnych danych teledetekcyjnych i pomiarów grawimetrycznych pozwoli podejmować bardziej skuteczne działania zarządzania zasobami wodnymi naszej planety zarówno w skali lokalnej, jak i globalnej, co ma bezpośredni wpływ na jakość życia i zrównoważony rozwój. Idea ta niesie też ze sobą ogromną korzyść w postaci zastosowania danych o większej rozdzielczości czasowo-przestrzennej do wzbogacania i skalowania danych grawimetrycznych ([Dee et al., 2011](#), [Döll et al., 2014](#), [Eicker et al., 2014](#)). Wykorzystanie potencjału tych danych oraz narzędzi statystycznych umożliwia otrzymanie szczegółowych informacji w skali lokalnej na temat stanu różnych obszarów. Umożliwia także na uzyskanie bardziej szczegółowych danych o zmianach ilości wody w analizach regionalnych, co ma duże znaczenie w badaniach klimatycznych, analizie zasobów wodnych i monitoringu suszy oraz powodzi.

Wielopoziomowość sytemu obiegu wody w przyrodzie prowadzi do wielowymiarowej złożoności prowadzenia pomiarów zmienności zawartości wody w glebie. Z tego względu rejestracja tego sygnału z pułapu satelitarnego stanowi nie lada wyzwanie dla badaczy z całego świata. Powstaje zatem konieczność prowadzenia analizy istotności czynników wpływających na rejestrację zmian poziomu wód gruntowych przez satelity GRACE i GRACE-FO, która to umożliwia wyodrębnienie głównych składowych bez utraty sygnału geofizycznego podczas opracowywania tychże danych.

4 Podstawy teoretyczne

4.1 Grawimetria satelitarna jako unikalna technika pomiarów zmiany przyspieszenia siły ciężkości związanej ze śledzeniem zmian mas

Globalne satelitarne pomiary przyspieszenia siły ciężkości dostarczają unikalnych danych o rozkładzie masy i procesach transportu masy w systemie ziemskim, związanych ze zmianami i procesami dynamicznymi zachodzącymi w hydrosferze, kriosferze, oceanach, atmosferze i statycznej części Ziemi. Dedykowane misje grawimetryczne, takie jak CHAMP (ang. *Challenging Minisatellite Payload*) (Reigber et al., 2002), GRACE (Tapley et al., 2004b, Wahr et al., 1998), GRACE-FO (Flechtner et al., 2016) i GOCE (ang. *Gravity field and steady-state Ocean Circulation Explorer*) (Tscherning et al., 2001) zainicjowały rewolucję w zrozumieniu procesów transportu masy wewnątrz Ziemi. Dzięki temu stało się możliwe osiągnięcie spektakularnych wyników naukowych i nowego spojrzenia na zachodzące procesy wewnątrz Ziemi i ich wzajemne oddziaływanie (Pail et al., 2015). Bez dyskusyjną sprawą jest konieczność walidacji tych rozwiązań, zwłaszcza gdy dostarczają ważnych informacji dotyczących prognoz zmian wód podpowierzchniowych. Aby zachowana była zrównoważona gospodarka wodna i aby możliwa była wczesna reakcja ludzkości na terenach, gdzie wzrasta ryzyko wystąpienia susz należy zwrócić uwagę na dokładność podawanych trendów i prognoz. W ostatnich latach misje GRACE i GRACE-FO i tworzone dzięki nim rozwiązania stały się głównym dostarczycielem ilościowych danych na temat obserwacji zmienności pola grawitacyjnego Ziemi oraz zjawisk z tym związanych.

4.2 Zmiany przyspieszenia wynikające ze zmian wilgotności gruntu, wyrażanej jako ΔTWS - opis zjawiska

Obserwowane miesięczne zmiany grawitacji są spowodowane miesięcznymi zmianami masy. Zmiany masy można uznać za skoncentrowane w bardzo cienkiej warstwie zmian poziomu wody w pobliżu powierzchni Ziemi (tj. w warstwie o grubości do kilku kilometrów). W rzeczywistości większość comiesięcznych zmian grawitacji jest spowodowana zmianami w magazynowaniu wody w zbiornikach hydrologicznych, przemieszczającymi się masami oceanicznymi, atmosferycznymi i lądowymi oraz wymianami masy między tymi komponentami systemu ziemskiego. Ich zasięg pionowy mierzy się w centymetrach równoważnej warstwy wody - ΔTWS . Niektóre zmiany grawitacji są spowodowane masową redystrybucją w „stałej” Ziemi, na przykład po dużym trzęsieniu ziemi lub w wyniku dostosowania izostatycznego post-lodowcowego. W takich przypadkach interpretacja zmian grawitacji w kategoriach „równoważnej warstwy wody” jest nieprawidłowa, nawet jeśli nadal można

obliczyć tę ilość (tj. przez usunięcie stałych efektów Ziemi w celu odizolowania zmian masy związanych z wodą). Podstawową metodę wznaczenia wartości ΔTWS wyjaśniono w (Wahr et al., 1998). Dane dotyczące zmienności pola grawitacyjnego są przechowywane w zharmonizowanej formie współczynników sferycznych harmonicznych. Wykorzystując ten sposób możliwe jest przeliczenie danych funkcjonałów zmian pola siły ciężkości w regularnej siatce (ang. *grid*) o zadanej rozdzielczości przestrzennej. Wielkość „oczek” siatki, tj. rozdzielczość przestrzenna, zależy od stopnia rozwinięcia funkcji sferycznych harmonicznych. Sprężone jest to bezpośrednio z częstotliwością pomiarów misji satelitarnych i w przypadku misji GRACE i GRACE-FO dla około miesięcznych rozwiązań maksymalny stopień rozwinięcia wynosić będzie 96. Dla dłuższego okresu obserwacji możliwe jest osiągnięcie wyższego maksymalnego stopnia rozwinięcia, ale wiąże się to z utratą obserwacji dynamiki zmian w polu siły ciężkości Ziemi i uśredniania obserwacji w dłuższych okresach. Siatki lądowe i oceaniczne są przetwarzane za pomocą różnych filtrów, które są dostrojone tak, aby jak najlepiej odfiltrowywać szum przy jednoczesnym zachowaniu prawdziwych sygnałów geofizycznych. Wzór umożliwiający wyznaczenie całkowitego ekwiwalentu wodnego przedstawia się następująco:

$$\Delta TWS_{(\theta,\lambda)} = \frac{\rho_e R}{3} \sum_{n=0}^{n_{max}} \frac{2n+1}{1+k'} \sum_{m=0}^n (\bar{C}_{mn} \cdot \cos(m\lambda) + \bar{S}_{mn} \cdot \sin(m\lambda)) \cdot \bar{P}_{mn} \cos(\theta) \quad (1)$$

gdzie θ, λ to współrzędne sferyczne punktu, w którym wyznaczany jest potencjał, R to promień Ziemi zdefiniowany w Międzynarodowej Konwencji dotyczącej Rotacji Ziemi i Systemów Referencyjnych (IERS2010, ang. *International Earth Rotation and Reference Systems Service Convention*) (Luzum and Petit, 2012), $\bar{C}_{mn}, \bar{S}_{mn}$ to znormalizowane współczynniki harmoniczne rozwinięcia potencjału siły ciężkości (współczynniki Stokesa) stopnia n i rzędu m , $\bar{P}_{mn}$ to znormalizowane funkcje Legendre’a stopnia n i rzędu m , k' oznacza parametr Ziemi elastycznej, określany mianem liczb Love’a uwzględniającymi deformację Ziemi spowodowaną efektami obciążenia, ρ_e to średnia gęstość Ziemi (Seo et al., 2006, Wahr et al., 1998).


4.3 Grawimetryczne misje satelitarne GRACE i GRACE-FO

Głównym celem naukowym misji GRACE był pomiar ziemskiego pola grawitacyjnego i jego zmienności w czasie z niespotykaną wcześniej dokładnością. Wykonanie zadania okazało się możliwe dzięki propozycji wystrzelenia dwóch satelitów (a nie jednego), które znajdują się obok siebie na tej samej ścieżce orbitalnej. Aby uwzględnić precyzyjnie położenie i siły niegrawitacyjne, oba satelity zostały wyposażone w kamery gwiazd i akcelerometry. Położenie i prędkość satelitów zmierzono za pomocą pokładowych anten GPS (ang. *Global Positioning System*) i (do celów walidacji) satelitarnych pomiarów laserowych (SLR, ang. *satellite laser ranging*). Koncepcja pomiarów satelitarnych między dwoma

satelitami na niskiej orbicie znana jest jako LL-SST (ang. *low-low satellite-to-satellite tracking*), podczas gdy śledzenie wysoko-niskie (HL, ang. *high-low*) odnosi się do pomiarów odległości między satelitami GPS umieszczonymi na wysokiej orbicie a segmentem kosmicznym GRACE na niskiej orbicie okołoziemskiej w celu dokładnego śledzenia aktualnej pozycji tej misji grawimetrycznej. Dodatkowo bliźniacze satelity (potocznie zwane *Tom i Jerry*) zostały połączone za pomocą łącza mikrofalowego w paśmie *K*, w celu zmierzenia dokładnej odległości separacji i szybkości jej zmian z dokładnością lepszą niż $0.1 \mu\text{m/s}$. Pomiarów te są bezpośrednio powiązane z sezonowymi zmianami w kontynentalnym cyklu hydrologicznym, utratą masy lodowej w dużych systemach lodowców na Grenlandii lub Antarktydzie, wzrostem poziomu mórz, procesami cyrkulacji oceanów lub wzrostem temperatury oceanów w kierunku biegunów Ziemi. Przez ponad dekadę operacyjnego działania GRACE zasadniczo przyczyniła się do lepszego zrozumienia systemu ziemskiego. Projekt GRACE działał trzy razy dłużej niż pierwotnie planowano, ale zakończył się w październiku 2017 r. ze względu na problemy z akumulatorem i brak paliwa. Misja GRACE powstała dzięki współpracy amerykańskich i niemieckich agencji kosmicznych (NASA (ang. *National Aeronautics and Space Administration*) i DLR (ger. *Deutsches Zentrum für Luft-und Raumfahrt*)). Operacje segmentu naziemnego GRACE są obecnie współfinansowane przez Niemieckie Centrum Geo-nauk (GFZ, ger. *GeoForschungsZentrum*) i Europejską Agencję Kosmiczną (ESA, ang. *European Space Agency*). NASA, ESA, GFZ i DLR wspierają kontynuację pomiarów przemieszczania się mas ziemskich na naszej planecie. Kluczowymi partnerami w projektowaniu, budowie i uruchomieniu misji były Laboratorium napędów odrzutowych JPL, (ang. *Jet Propulsion Laboratory*), CSR (ang. *Center for Space Research*), GFZ, a także konsorcja Astrium GmbH, Space Systems Loral, Onera i Eurockot GmbH. Wystrzelone 17 marca 2002 r. bliźniacze satelity GRACE przez 15 lat dokonywały szczegółowych pomiarów zmian pola grawitacyjnego Ziemi, rewolucjonizując badania dotyczące zmienności lądowych, podziemnych i oceanicznych zasobów wodnych, a także trzęsień ziemi i deformacji skorupy ziemskiej. Korzyści płynące z ciągłego obserwowania naszej planety przez satelity GRACE doprowadziły do kontynuacji projektu pod nazwą GRACE-FO. Będzie on utrzymywać niezwykle udaną pracę swojego poprzednika, testując nową technologię zaprojektowaną w celu poprawienia i tak niezwyklej precyzji systemu pomiarowego swojego poprzednika. GRACE-FO, który został uruchomiony 22 maja 2018 r. monitoruje śledzenie obiegu wody na Ziemi w celu badania zmian podziemnych zasobów wodnych, ilości wody w dużych jeziorach i rzekach, wilgotności gleby, pokrywy lodowej i lodowców oraz wahań poziomu morza. Badania te zapewniają unikalny obraz klimatu Ziemi i przynoszą daleko idące korzyści ekonomiczno-gospodarcze ludności świata (Flechtner et al., 2016, Tapley et al., 2004b, Wahr et al., 1998).

Satelity GRACE wyposażone są w szereg przyrządów umożliwiających precyzyjne wyznaczanie pola siły ciężkości. Są to między innymi:

- K-band Ranging System (KBR) - zapewnia precyzyjne (w granicach 10 μm) pomiary zmiany odległości między dwoma satelitami potrzebnej do pomiaru fluktuacji grawitacji. Ideę pomiaru zaprezentowano na rysunku (2).
- Ultra Stable Oscillator (USO) - zapewnia generowanie częstotliwości dla systemu określania zakresu w paśmie K.
- Super STAR Accelerometers (ACC) - dokładnie mierzy przyspieszenia niegrawitacyjne działające na satelitę.
- Star Camera Assembly (SCA) - precyzyjnie określa orientację dwóch satelitów, śledząc je względem położenia gwiazd.
- Coarse Earth and Sun Sensor (CES) - zapewnia ogólne, niezawodne i solidne, ale dość zgrubne śledzenie Ziemi i Słońca. Używany podczas początkowej fazy pomiarów i zawsze, gdy GRACE działa w trybie awaryjnym.
- Center of Mass Trim Assembly (CMTA) - precyzyjnie mierzy przesunięcie między środkiem masy satelity a „odporną na przyspieszenie” masą i dostosowuje środek masy w razie potrzeby podczas lotu.
- Black-Jack GPS Receiver and Instrument Processing Unit (GPS) - zapewnia cyfrowe przetwarzanie sygnału; mierzy zmianę odległości względem konstelacji satelity GPS.
- Globalstar Silicon Solar Cell Arrays (GSA) - obejmuje zewnętrzną powłokę statku kosmicznego i generuje moc.



Rysunek 2: Idea pomiaru odległości pomiędzy bliźniaczymi satelitami GRACE-FO. Źródło: <https://gracefo.jpl.nasa.gov/>.

W porównaniu do misji GRACE, misja GRACE-FO wyposażona została w interferometryczny laserowy system pomiaru odległości LRI (ang. *Laser Range Interferometry*). Umożliwiło to określenie odległości pomiędzy satelitami ze zwiększoną dokładnością do 2000% w porównaniu do zastosowania KBR ([Sheard et al., 2012](#)).

4.4 Zastosowania satelitarnych danych grawimetrycznych

Tylko w USA (ang. *United States of America*), powódzie na terenach wewnętrznych powodują średnio 133 ofiary i straty w wysokości 4 miliardów dolarów rocznie. Poprawa prognoz długookresowych mogłaby znacznie zminimalizować straty związane z powodzią, jednak wymaga to dokładnych informacji na temat stanu hydrologicznego całego obszaru zlewni rzeki, czyli całkowitej zasobności wody. Misja satelitarna GRACE umożliwia obserwację miesięcznych zmian w całkowitej zasobności wody w dużych zlewniach rzecznych (o powierzchni $> 200000 \text{ km}^2$) z wykorzystaniem pomiarów zmian w polu grawitacyjnym Ziemi. Sygnał składowania wody na lądzie określa, zmienną w czasie, zdolność terenu do magazynowania i przetwarzania wody oraz uwzględnia wodę znajdującą się pod powierzchnią ziemi. Może zatem być wykorzystany zarówno do monitorowania i prognozowania zjawisk powodziowych, jak i susz. Charakterystyka suszy obejmuje wiele elementów, takich jak typ, częstotliwość, czas trwania, wielkość, nasilenie oraz rozmiar występowania zjawiska. Metoda oszacowania deficytu zasobów za pomocą danych z misji GRACE może być wykorzystana w połączeniu z tradycyjnymi metodami prognozowania opadów do oceny ryzyka powodzi, a także może przynieść dodatkowe korzyści w globalnym modelowaniu poprzez uwzględnienie efektywnej pojemności magazynowania ([Zaitchik et al., 2008](#)). Obserwacje zjawisk naturalnych i ciągły ich monitoring są niezwykle ważne pod kątem bezpieczeństwa. Obserwacje ekstremalnych zjawisk takich, jak susze oraz powódzie ma ogromne znaczenie dla ludzi. Dostępne rozwiązanie w postaci misji GRACE umożliwia śledzenie tych ekstremalnych hydrologicznych zdarzeń na świecie.

Dane grawimetryczne znajdują zastosowanie przede wszystkim w następujących obszarach tematycznych:

- Monitorowanie zmian ilości wody na Ziemi - misja GRACE umożliwia pomiar zmian w ilości wody na Ziemi, w tym akumulacji i deficytów wód gruntowych, zbiorników wodnych, lodowców i pokrywy śnieżnej ([Kusche et al., 2016](#), [Rodell et al., 2018](#)).
- Badanie zmian poziomu morza - GRACE jest używane do monitorowania zmian w poziomie oceanów, co pozwala naukowcom na analizę globalnych zmian klimatycznych i zrozumienie ich wpływu na poziom mórz i oceanów ([Reager et al., 2016](#), [Rietbroek et al., 2016](#)).

- Monitorowanie zmian w lodowcach i pokrywie lodowej: misje grawimetryczne umożliwiają pomiar zmian objętości i masy lodowców oraz pokrywy lodowej na Antarktydzie i Grenlandii, co jest kluczowe dla monitorowania zmian klimatycznych i oceny ich wpływu na podnoszenie poziomu morza ([Sasgen et al., 2013](#), [Wouters et al., 2019](#)).
- Zrozumienie ruchów mas ziemskich - GRACE pomaga w badaniu ruchów mas ziemskich, takich jak pływy, tektoniczne przesunięcia, zmiany w masie lądowej i migracji cieczy w płaszczu ziemskim lub zmiany ciśnienia na dnie oceanów ([Landerer et al., 2015](#), [Poropat et al., 2018](#)).
- Prognozowanie ekstremalnych zjawisk atmosferycznych i klęsk żywiołowych - satelitarne dane grawimetryczne są wykorzystywane do prognozowania ekstremalnych zjawisk atmosferycznych i klimatycznych, takich jak susze i powódzie, poprzez monitorowanie zmian w ilości wody w różnych regionach ([Chen et al., 2007](#), [Liu et al., 2020](#), [Zhao et al., 2017a](#)).
- Wspieranie badań naukowych i nauk o klimacie - misja GRACE dostarcza cenne dane naukowe i pomaga w zrozumieniu globalnych zmian klimatycznych, bilansów masy lądowej i innych zjawisk geofizycznych ([Tapley et al., 2019](#)).

Już ta syntetyczna analiza wskazuje, że większość zastosowań związana jest z analizą zmian zasobów wody i ich dystrybucją w czasie i przestrzeni. W Polsce prowadzono prace w temacie wykorzystania danych GRACE w kontekście wyznaczania wariacji podpowierzchniowych zasobów wodnych (GWS, ang. *groundwater storage variations*) przez ([Birylo and Rzepecka, 2023](#), [Birylo et al., 2018](#), [Rzepecka et al., 2016](#), [Śliwińska et al., 2019](#)), w dziedzinie deformacji ([Kermarrec et al., 2023](#), [Lenczuk et al., 2023, 2020](#), [Rajner and Liwosz, 2017](#)), ruchu bieguny ([Nastula and Śliwińska, 2020](#), [Nastula et al., 2022](#), [Śliwińska et al., 2020a, 2021a, 2020b, 2021b](#)) oraz dynamicznych systemach wysokościowych ([Godah et al., 2017, 2020](#), [Szelachowska et al., 2022, 2017](#)). Prace badawcze zrealizowane w ramach niniejszej rozprawy doktorskiej stanowią nowatorskie podejście do wykorzystania grawimetrycznych misji satelitarnych na tle badań prowadzonych dotychczas w Polsce.

4.5 Charakterystyka pomiarów teledetekcyjnych zorientowanych na badanie zmian wilgotności (AMSR-E)

Wilgotność gleby wyrażona jako SM to istotna zmienna hydrologicznego stanu gleby, która znajduje się w kręgu zainteresowania różnorodnych dyscyplin naukowych, o istotnym znaczeniu dla wielu zastosowań w meteorologii, hydrologii, klimatologii i ekologii

(Robinson et al., 2008). Metody teledetekcyjne do szacowania SM są stosowane od lat 70. XX wieku. Aktywna i pasywna teledetekcja mikrofalowa zapewnia obserwację SM w skali globalnej i regionalnej (Bartalis et al., 2007, Chen et al., 2018, Jackson et al., 2010, Kerr et al., 2016, Koike et al., 2004, Ulaby, 1982, Vinnikov et al., 1999, Wagner et al., 2013). Rozwój technik teledetekcyjnych zaowocował możliwością prowadzenia badań związanych z SM w skali globalnej z subdobową częstotliwością. Do wyznaczania SM z powodzeniem wykorzystano mikrofalowe pomiary teledetekcyjne (Babaeian et al., 2019).

Jednym z urządzeń stosowanych do pomiaru zawartości wody w glebie jest sensor AMSR-E, czyli pasywny wielopasmowy czujnik satelitarny umieszczony na satelicie Aqua programu NASA o nazwie EOS (ang. *Earth Observing System*). AMSR-E wykorzystuje pasma X i C do pomiaru obiegu wody i określania zawartości SM odpowiadającej głębokości odpowiednio (2.5–3.75 cm) i (3.75–7.5 cm). Ze względu na fakt znacznych zakłóceń częstotliwości radiowych, oznaczanych jako RFI (ang. *radio frequency interference*), w paśmie C (6.9 i 10.7 GHz), to pasmo X było szeroko stosowane do wyznaczania SM (Njoku et al., 2005). We wszystkich pasmach sensor wykonuje pomiary w pionowej i poziomej polaryzacji. Promieniowanie mikrofalowe emitowane przez Ziemię jest zbierane przez reflektor paraboliczny o średnicy 1.6 metra, który skanuje Ziemię wzdłuż powierzchni stożkowej, utrzymując stały kąt padania na powierzchnię Ziemi wynoszący 55°. System ten wykorzystuje sześć stopni swobody, które przekazują promieniowanie do radiometrów w celu pomiaru. Do kalibracji wykorzystuje się obserwacje promieniowania kosmicznego tła oraz obiektu referencyjnego znajdującego się na pokładzie satelity. Rozdzielczość przestrzenna pojedynczych pomiarów różni się od 5.4 km przy 89.0 GHz do 56 km przy 6.9 GHz.

Woda istnieje w naturze w różnych formach i stanach, takich jak chmury, para wodna i deszcz w atmosferze, woda morska i lód morski, rzeki, gleba, roślinność i pokrywa śnieżna. Związana jest bezpośrednio z wymianą energii w przyrodzie. Cząsteczka wody H_2O , która odgrywa kluczową rolę w takim obiegu wody, ma unikalne właściwości w paśmie mikrofalowym i emituje słabe fale mikrofalowe w zależności od swojego stanu, kształtu i temperatury. AMSR-E mierzy te słabe sygnały mikrofalowe emitowane przez świat przyrody. Mikrofały emitowane z powierzchni ziemi są absorbowane i rozpraszane przez deszcz, chmury i parę wodną, gdy przechodzą przez atmosferę, co powoduje ich osłabienie. Jednocześnie, mikrofały są również emitowane przez deszcz, chmury i parę wodną. Ponadto podlegają rozpraszaniu przez krople deszczu i cząsteczki chmur w kierunku AMSR-E z innych stron.

Możliwości pomiarowe sensorów AMSR-E dają szeroki zakres zastosowań. System ten mierzy opady atmosferyczne, ilość wody w chmurach, parę wodną, prędkość wiatru na powierzchni morza, temperaturę powierzchni morza, lód, śnieg i wilgotność gleby.

Dzięki temu możliwe jest przeprowadzanie pomiarów w różnych warunkach pogodowych, co wspiera badania naukowe oraz monitorowanie globalnych zmian klimatycznych.

4.6 Wyznaczenie wilgotności gleby wyrażonej jako SM za pomocą mikrofalowych sensorów AMSR-E

Produkt udostępniany z misji AMSR-E to zawartość wilgoci gleby oznaczanej jako SMC (ang. *Soil Moisture Content*). Reprezentuje to wilgotność gleby blisko powierzchni gruntu. Pokrycie tego produktu obejmuje tylko obszary lądowe, a jednostką jest zawartość objętościowa wody podawana w procentach (Njoku et al., 2003). Pasywne czujniki mikrofalowe (radiometry), jak już wspomniano, rejestrują naturalną emisję mikrofalową oznaczaną jako Tb (temperaturę jasnościową), która zależy od emisyjności i fizycznej temperatury emitującego ciała. W przypadku pasywnego szacowania wilgotności gleby, konieczna jest znajomość fizycznej temperatury powierzchni ziemi. Równania odbicia Fresnela opisują emisyjność gładkiej powierzchni odkrytego gruntu w zależności od kąta padania promieniowania i założonej stałej dielektrycznej gruntu. W uproszczeniu wzór dla wyznaczania zawartości wilgotności gleby na podstawie pomiarów AMSR-E kształtuje się następująco:

$$SMC = a \cdot \frac{Tb}{Tb_{max}} + b \quad (2)$$

gdzie Tb to obserwowana temperatura jasności mikrofalowej, Tb_{max} to maksymalna temperatura jasności mikrofalowej dla suchej gleby, a i b to współczynniki kalibracyjne, które są dostosowywane na podstawie danych referencyjnych. Ukształtowanie powierzchni gleby, jej struktura oraz pokrycie roślinnością na powierzchni gleby wpływają na emisję mikrofalową, dodając swoje własne sygnały do emisji powierzchni gleby. Aby symulować te efekty, naukowcy opracowali model $\tau - \omega$, który bierze pod uwagę grubość optyczną (τ) i albedo pojedynczego rozpraszania roślinności (ω) jako parametrów wejściowych (Mo et al., 1982). Model ten jest podstawą dla wielu innych modeli pasywnego szacowania wilgotności gleby mikrofalowej, takich jak SCA (ang. *Soil Canopy Atmosphere*), model L-MEB (ang. *Land Microwave Emission Model for Brightness Temperature*), CMEM (ang. *Community Microwave Emission Model*) i LPRM (ang. *Land Parameter Retrieval Model*) (Drusch et al., 2009, Mladenova et al., 2014, Wigneron et al., 2007).

Prawidłowe oszacowanie wilgotności gleby w pobliżu linii brzegowej, wokół dużych jezior i bagien oraz na obszarach z dużymi przestrzeniami gęstego lasu, na podstawie pasywnej techniki mikrofalowej jest utrudnione. Na styku powierzchni lądu oraz mórz/jezior obserwowany sygnał charakteryzuje się znaczną wariancją i niepewnością przez bliskość różnych ośrodków. W obszarach o charakterystyce gęstego pokrycia roślinnością obecność skomplikowanej struktury roślinnej wpływa na oddziaływanie fal mikrofalowych z powierzchnią gleby, co również utrudnia precyzyjne pozyskiwanie danych dotyczących SM.

Ponieważ radiometry mikrofalowe mogą rejestrować dane regularnie z dużą częstotliwością, ten produkt jest wykorzystywany do monitorowania dużych obszarów uprawnych na kontynentach. Dostępne są dwa rodzaje produktów: produkt badawczy i produkt standardowy. Algorytm obliczania wilgotności gleby wykorzystuje dane o pokryciu roślinnością z MODIS (ang. *Moderate Resolution Imaging Spectroradiometer*) w celu uwzględnienia wpływu roślinności. Przy czym w przypadku produktu badawczego wykorzystywane są aktualne dane MODIS, podczas gdy produkt standardowy opiera się na wartościach dla tzw. normalnego roku. W związku z tym, produkt badawczy powinien być stosowany w obszarach o dużych międzyrocznych zmianach w pokryciu roślinności, takich jak obszary uprawne. Należy jednak zauważyć, że publikowanie produktu badawczego jest opóźnione o około jeden miesiąc w porównaniu do produktu standardowego. Proces wyznaczania wilgotności jest realizowany w kilku etapach. Pierwszym krokiem jest przeprowadzenie korekcji atmosferycznej, aby uwzględnić wpływ atmosfery na sygnały mikrofalowe. W tym celu wykorzystuje się informacje o temperaturze atmosfery i zawartości pary wodnej. Następnie algorytm uwzględnia wpływ roślinności na sygnały mikrofalowe. Wykorzystuje się do tego dane o pokryciu roślinności, które mogą pochodzić z różnych źródeł, takich jak wspomniane dane z sensora MODIS. Dalej w algorytmie stosowana jest analiza wieloobszarowa, która bierze pod uwagę różnice w sygnałach mikrofalowych między różnymi obszarami, co może wskazywać na różnice w wilgotności gleby. Ostatecznie wyznaczone wartości produktu dotyczącego SM są kalibrowane i weryfikowane przy użyciu danych referencyjnych, takich jak pomiary terenowe wilgotności gleby, aby zapewnić pożądaną dokładność wyników.

4.7 Przegląd dotychczasowych badań opublikowanych w literaturze naukowej

Dokumentacja nagłych zmian środowiskowych była wielokrotnie prowadzona na całym świecie. W Azji badania przeprowadzone były w Indiach (Rodell et al., 2009, Tiwari et al., 2009), Chinach (Chao et al., 2016, Feng et al., 2013, Tang et al., 2014), na Bliskim Wschodzie (Forootan et al., 2014, Joodaki et al., 2014, Voss et al., 2013). W pracy (Gouweleeuw et al., 2017) zastosowano jednodniowe rozwiązania GRACE do monitorowania zdarzeń powodziowych w delcie Gangesu-Brahmaputry w 2004 i 2007 r. W badaniach opublikowanych w (Jain et al., 2013) naukowcy zbadali możliwości zastosowania GRACE w wykrywaniu powodzi o ograniczonym zasięgu czasoprzestrzennym. W Ameryce Północnej także prowadzono badania, gdzie na przykładzie Kalifornii można obserwować znaczące zmiany ΔTWS w czasie (Scanlon et al., 2012a,b). W Ameryce Południowej Chen et al. (2010) przeanalizowali zmiany EWH otrzymane dzięki GRACE, aby zbadać

przebieg ogromnej powodzi na terenach Puszczy Amazońskiej w 2009 r. W Afryce zastosowania misji GRACE w porównaniu do globalnych i regionalnych modeli hydrologicznych miało szczególne znaczenie z uwagi na niezwykle cenne zasoby wody pitnej (Klees et al., 2008), i wskazywały na korzyści płynące z satelitarnych pomiarów grawimetrycznych do szacowania zasobów wód podziemnych. Potencjał misji GRACE został również ukazany na podstawie analizy głównych zbiorników wodnych w Afryce, gdzie dzięki kombinacji z lokalnymi pomiarami in situ wyestymowano wariancje podpowierzchniowych zasobów wodnych (Ramillien et al., 2014). Na starym kontynencie również tematyka związana z zastosowaniem grawimetrii satelitarnej była podejmowana. Andersen et al. (2005) przeanalizowali na podstawie danych GRACE suszę w 2003r., widoczną również w pomiarach prowadzonych przez grawimetry SG. Wpływ ekstremalnych zdarzeń pogodowych w Europie został zbadany w (Seitz et al., 2008), gdzie przedstawiono wysoką korelację modeli GRACE z danymi atmosferycznymi i hydrologicznymi. W Australii studium przypadku przeprowadzono w (Tregoning et al., 2012), gdzie autorzy dokonali oceny wiarygodności i użyteczności wykorzystania wyznaczenia całkowitego ekwiwalentu wodnego za pomocą danych z misji GRACE na podstawie danych lokalnych.

Podczas pracy z danymi GRACE niezwykle ważnym czynnikiem wpływającym na ostatecznie wyznaczone wartości funkcjonałów jest odpowiednie opracowanie danych. W literaturze wielokrotnie poruszany był problem filtracji danych GRACE jednakże ze względu na ograniczoną liczbę jednorodnych i spójnych szeregów czasowych nadal istnieje duży potencjał badawczy w kontekście oceny wpływu czynników zarówno lokalnych, jak i ekstremalnych wydarzeń klimatycznych na ostateczne wartości dostarczane przez misję GRACE. Pojawiające się też kolejne wersje reprocessingu danych GRACE wymagały ponownego sprawdzenia warunków, dla których można obserwować większą zbieżność sygnałów GRACE do wartości rzeczywiście zmierzonych na powierzchni Ziemi i oszacowywać błąd pomiaru. Prace w tym temacie prowadzone były przez (Bhanja et al., 2016, Böning et al., 2008, Dahle et al., 2019, Macrander et al., 2010, Poropat et al., 2018, Syed et al., 2008) i obejmowały estymację budżetu błędów na podstawie danych z modeli hydrologicznych, pomiarów in-situ poziomu wód podpowierzchniowych oraz anomalii ciśnienia dna oceanicznego. Prace dotyczące porównania grawimetrycznych pomiarów satelitarnych z naziemnymi w rejonie centralnej Europy dokonano w (Abe et al., 2012, Crossley et al., 2012, Godah et al., 2015, Neumeier et al., 2008) wskazując na trudności w określeniu poziomu rozmycia danych a stopniem straty sygnału geofizycznego. Dane GRACE charakteryzują się dużą zależnością dokładności wyznaczanych funkcjonałów od odpowiedniego sposobu ich opracowania. Istniejąca mnogość sposobów filtracji danych GRACE oraz idąca w parze zależność od czynników przestrzennych globalnych, jak: odległość od mórz i oceanów, ukształtowanie terenu, trendy globalne zmian zasobu wód podziemnych,

oraz lokalnych, takich jak: czynniki urbanistyczne, lokalne efekty hydrogeologiczne, głębokość warstw wodonośnych sprawiają, że istnieje potencjał badawczy w zrozumieniu tychże współzależności mających wpływ na wyznaczenie zmian w polu siły ciężkości Ziemi.

Wpływ oceny przestrzennych i czasowych zmian wilgotności gleby na zmiany klimatyczne został opisany w wielu badaniach naukowych (Betts et al., 1994, Engman, 1992, Entekhabi et al., 1994, Fast and McCorcle, 1991, Jackson et al., 1987, Petropoulos et al., 2014, Saha, 1995, Topp et al., 1980). Przestrzenne i czasowe zmienności w ilości wody w glebie zostały solidnie udokumentowane we wcześniejszych badaniach dotyczących wilgotności gleby (Crow et al., 2012, Famiglietti et al., 2008, Vereecken et al., 2014) oraz Δ TWS (Landerer and Swenson, 2012, Tapley et al., 2004a, Zhao et al., 2017b). Z perspektywy hydrologii, badanie wzorców przestrzennych i czasowych obserwacji wilgotności gleby oraz Δ TWS jest kluczowe dla zrozumienia zachowania tych zmiennych. W literaturze można znaleźć metody, które analizują jedynie zmienność w przestrzeni (Haining et al., 2010, Khaki et al., 2017), jak i takie, które koncentrują się tylko na analizie w czasie, opierając się na badaniu szeregów czasowych (Fu, 2011, Sprott and Sprott, 2003, Vishwakarma et al., 2021a). Istnieją również techniki, które biorą pod uwagę zarówno przestrzenne, jak i czasowe aspekty danych Δ TWS i wilgotności gleby, na przykład TSA (ang. *temporal stability analysis*) (Martínez-Fernández and Ceballos, 2005, Wang et al., 2018), TC (ang. *triple collocation*) (Crow et al., 2015, Gruber et al., 2017, Hasan and Tarhule, 2021, Yin and Park, 2021) oraz empiryczne funkcje ortogonalne (EOF, (ang. *Empirical Orthogonal Functions*)) (Eom et al., 2017, Lei et al., 2012, Navarra and Simoncini, 2010, Schrama et al., 2007, Yoo and Kim, 2004). W każdym przypadku, bez względu na to, czy analiza jest przeprowadzana w kontekście czasowym czy przestrzenno-czasowym, ważnym wnioskiem badaczy jest znaczenie wilgotności gleby jako czynnika wpływającego na sygnał Δ TWS.

Teledetekcyjne obserwacje również były z powodzeniem wykorzystywane do określenia wilgotności gleby (Babaeian et al., 2019, Balenzano et al., 2021, Peng et al., 2021). Aktywne i pasywne obserwacje mikrofalowe umożliwiają analizę wilgotności gleby na skalę globalną i regionalną (Bartalis et al., 2007, Chen et al., 2018, Jackson et al., 2010, Kerr et al., 2016, Koike et al., 2004, Ulaby, 1982, Vinnikov et al., 1999, Wagner et al., 2013). Te technologie są szeroko wykorzystywane w badaniach hydrologii i klimatu, pozwalając na zrozumienie zmian środowiskowych (Njoku and Entekhabi, 1996). Jednym z kluczowych sensorów teledetekcyjnych dostarczających danych o wilgotności gleby była misja AMSR-E. Badania porównawcze między SM z misji AMSR-E a sygnałami Δ TWS z misji GRACE wykazały silne korelacje w poszczególnych regionach na świecie, co potwierdza znaczenie danych mikrofalowych w monitoringu hydrologicznym. Przeprowadzone analizy skupiają się na zmienności zarówno przestrzennej, jak i czasowej, z wykorzystaniem różnych me-

to takich, jak analiza korelacji, przesunięcia czasowe i analiza głównych składowych. Uzyskane wyniki są istotne dla zrozumienia dynamiki zmian warunków hydrologicznych w różnych obszarach i mogą być pomocne w monitorowaniu suszy i innych zmian środowiskowych (Abelen et al., 2015, 2011, Chen et al., 2012, 2013, Du et al., 2019, Seo et al., 2010, Wang and Forman, 2020, Wang et al., 2021). Praca z danymi AMSR-E wymaga wysokich umiejętności pracy na dużych zbiorach danych. Ilość danych niezbędna do przetworzenia często przekracza możliwości komputerów o przeciętnej mocy obliczeniowej, co z jednej strony jest wyzwaniem, ale z drugiej pozostawiło nie poruszoną przez naukowców w dostatecznym stopniu tematykę badawczą. Mimo że istnieją badania przeprowadzone w celu oceny ekstremalnych zjawisk hydrologicznych za pomocą danych z misji GRACE i AMSR-E, pozostaje pewna luka w opublikowanej literaturze dotycząca zbieżności sygnałów ΔTWS i SM w kontekście danych o pokryciu terenu, takich jak warunki glebowe, pokrycie roślinności, stopień urbanizacji i użytkowania rolniczego. Ze względu na to, że dane zbierane przez czujniki grawimetryczne mają mniejszą częstotliwość pomiarów i rozdzielczość przestrzenną niż pomiary mikrofalowe, istotne jest zbadanie zbieżności tych sygnałów. **Kluczowe jest znalezienie odpowiedzi na pytanie: czy możliwe jest wykorzystanie informacji zawartych w danych zebranych przez czujniki charakteryzujące się większym szumem i wariancją sygnału, takimi jak AMSR-E, w globalnej analizie zmienności ΔTWS z satelitów GRACE.**

Prawie roczna przerwa między GRACE i GRACE-FO zrodziła pytania o przyszłość obserwacji GRACE-FO, a co za tym idzie możliwości ciągłego monitorowania i zmian klimatu. Wraz z rosnącymi możliwościami obliczeniowymi komputerów rośnie znaczenie metod uczenia maszynowego w rozwiązywaniu problemów związanych z rekonstrukcją sygnału. Po zakończeniu misji GRACE-FO dalej będzie istnieć potrzeba kartowania różnych zjawisk i ich zmian na podstawie istniejących danych oraz prowadzenia dalszych badań w obszarze modelowania hydrologicznego. Rosnące zainteresowanie wykorzystaniem modeli stosujących algorytmy sztucznej inteligencji w zastosowaniach hydrologicznych daje nowe możliwości rozwiązywania tradycyjnie złożonych problemów, w tym rekonstrukcji danych (Hamshaw et al., 2018). W wielu istniejących pracach naukowych przedstawiono zastosowanie modeli uczenia maszynowego. Pierwsze próby z wykorzystaniem EOF opisano w pracy (Becker et al., 2011), gdzie użyto historycznych danych z dorzecza Amazonki. Sun et al. (2020b) zaprezentowali rekonstrukcję szeregów czasowych związanych z ΔTWS dla 60 wybranych dorzeczy rzecznych. W tej publikacji dokonano kompleksowego porównania rekonstrukcji ΔTWS za pomocą głębokiej sieci neuronowej (DNN, ang. *deep neural network*), sezonowego autoregresyjnego modelu ruchomej średniej (SARIMAX, ang. *seasonal autoregressive integrated moving average model*) oraz algorytmów uczenia maszynowego (ML, ang. *machine learning*) w podejściu czasowym. Seyoum et al. (2019) zasto-


sowali drzewa decyzyjne do odtworzenia anomalii poziomu wód gruntowych o wysokiej rozdzielczości, poprawiając dane pochodzące z modelu GLDAS (ang. *Global Land Data Assimilation System*) za pomocą obserwacji terenowych. [Jing et al. \(2020\)](#) zastosowali podejście przestrzenno-czasowe w badaniu przypadku dorzecza Nilu. W ich algorytmach wykorzystano metody las losowy (ang. *random forest*), ekstremalne wzmocnienie gradientu (XGBoost, ang. *extreme gradient boosting*) oraz regresję logistyczną, ustanawiając standardy dla wysoce dokładnej rekonstrukcji parametrów hydrologicznych na podstawie zbioru danych GLDAS-2. [Sun et al. \(2021\)](#) zaprezentowali rekonstrukcję TWS, używając danych NOAA i CLSM dla największych dorzeczy w USA, a także określili znaczenie predyktorów. [Seyoum and Milewski \(2017\)](#) wykorzystali z kolei sztuczne sieci neuronowe (ANN, ang. *artificial neural networks*). [Irrgang et al. \(2020\)](#) oraz [Mo et al. \(2021\)](#) zaprezentowali natomiast wydajność konwolucyjnych sieci neuronowych (CNN, ang. *convolutional neural network*) w kontekście wypełniania luki danych Δ TWS pomiędzy misjami GRACE i GRACE-FO. [Ahmed et al. \(2019\)](#) przeprowadzili badania dotyczące dorzeczy afrykańskich, także z zastosowaniem CNN. [Sun \(2013\)](#) użył wielowarstwowych perceptronów (MLP, ang. *multilayer perceptron*) oraz architektur ANN do prognozowania zmian poziomu wód gruntowych. [Sun et al. \(2019\)](#) wykorzystali model CNN o architekturach VGG16, Unet i Segnet do obszaru Indii, dowodząc skuteczności sieci typu enkoder-dekoder w rekonstrukcji Δ TWS.

Metody wytłumaczalnej sztucznej inteligencji XAI (ang. *explainable artificial intelligence*) ([Arrieta et al., 2020](#)) wprowadzają benefity w postaci interpretacji głębokich zależności pomiędzy parametrami wejściowymi (cechami) a przewidywanymi wartościami. W dotychczasowych pracach naukowych można znaleźć przykłady użycia z powodzeniem zaawansowanych metod dotyczących rekonstrukcji sygnału Δ TWS na podstawie danych z modelu GLDAS. Niewiele natomiast jest prac dotyczących badania istotności użytych cech. Brakuje też wskazania na różnice w podejściach czasowych i czasowo-przestrzennych do rekonstrukcji sygnału Δ TWS. **Podążając za tym tokiem rozumowania powstała przestrzeń do przeprowadzenia prac badawczych dotyczących analizy istotności czynników wpływających na rejestrację zmian zawartości wody w glebie rejestrowanych przez satelity GRACE i GRACE-FO i zbadania w jakich warunkach możliwe by było synergiczne wykorzystanie obserwacji dostarczanych do modeli hydrologicznych za pomocą satelitarnych sensorów o odmiennej charakterystyce.**

5 Metodyka badań

W tejże rozprawie doktorskiej wprowadzono strukturalny plan działania, który umożliwia systematyczne zbieranie, analizowanie i interpretowanie danych w celu uzyskania odpowiedzi na postawione pytania badawcze oraz weryfikacji hipotez. Niniejszy rozdział przedstawia metodykę badań naukowych, czyli zebrany zbiór zasad, technik, procedur oraz zastosowanych narzędzi. Na podstawie istniejącej literatury i zebranych doświadczeń wyznaczono odpowiednie cele badawcze, a dalej zaprojektowano badania, które obejmowały: zebranie i opracowanie danych (rozdziały: (5.1 - 5.3)), wyselekcjonowanie i zastosowanie metod przetwarzania (rozdziały: (5.4 - 5.6)), określenie kryteriów porównawczych (rozdział: (5.7)) oraz metod potrzebnych do przeprowadzenia analizy i interpretacji (rozdziały: (5.8 - 5.10)). Wszelkie prace obliczeniowe wykonano przy pomocy własnych skryptów napisanych w językach programowania Matlab i Python.

Uproszczony przebieg oraz strukturę prac badawczych przedstawiono na rysunku (3).



Rysunek 3: Schemat ideowy metodyki badań oraz struktura prac. Źródło: Opracowanie własne.

5.1 Przetwarzanie danych GRACE oraz GRACE-FO

W celu przedstawienia ziemskiego pola siły ciężkości, najczęściej stosuje się rozwinięcie funkcji reprezentującej potencjał siły grawitacyjnej w szereg funkcji harmonicznych sferycznych. Potencjał grawitacyjny (potencjał siły przyciągania) V w dowolnym punkcie na powierzchni Ziemi można zapisać w funkcji współrzędnych sferycznych jako:

$$V_{(r,\theta,\lambda)} = \frac{GM}{R} \sum_{n=0}^{n_{max}} \left(\frac{a}{r}\right)^n \sum_{m=0}^n (\bar{C}_{mn} \cdot \cos(m\lambda) + \bar{S}_{mn} \cdot \sin(m\lambda)) \cdot \bar{P}_{mn} \cos(\theta) \quad (3)$$

gdzie $\theta, \lambda, R, \bar{C}_{mn}, \bar{S}_{mn}, n, m, \bar{P}_{mn}$ są zgodne z oznaczeniami i objaśnieniami występującymi we wzorze (1), r - to promień wodzący, GM to geocentryczna stała grawitacyjna, czyli iloczyn stałej grawitacji i masy ziemi, a to dłuższa półoś referencyjnej elipsoidy ziemskiej zdefiniowanej w IERS2010

Modele geopotencjału zostały opracowane na podstawie satelitarnych obserwacji zmian pola siły ciężkości Ziemi. Stworzenie globalnego modelu geopotencjału sprowadza się do wyznaczenia znormalizowanych współczynników $\bar{C}_{mn}, \bar{S}_{mn}$. Pozycje satelity w poszczególnych epokach oraz wartości potencjału grawitacyjnego pozyskane z misji GRACE pozwalają, wykorzystując metodę Gaussa-Markova, dokonać estymacji współczynników harmonicznych sferycznych.

Współczynniki mają swoją interpretację fizyczną. Przykładowo C_{10}, C_{11}, S_{11} oznaczają centrum masy, C_{20} - spłaszczenie grawimetryczne Ziemi, C_{21}, S_{21} - ruch bieguna. Współczynnik C_{20} znany jest również jako „ $J2$ ”, czyli współczynnik opisujący spłaszczenie statyczne, czyli w momencie bezwładności traktującym Ziemię jako bryłę sztywną. Aby współczynniki $J2$ i C_{20} były tożsame należy skorzystać z zależności $J2 = -C_{20} * \sqrt{5}$ (Chen et al., 2016, Sun et al., 2016a,b). Od 1979r. satelity obserwują stały spadek $J2$. Ten długoterminowy spadek wynika głównie z wypiętrzania izostatycznego post-lodowcowego. Stały spadek jest modulowany przez redystrybucję masy oceanu i lodu (Cox and Chao, 2002). Przyspieszona utrata masy lodowej z pokrywy lodowej Grenlandii i Antarktydy wydaje się w coraz większym stopniu mieć znaczenie w obserwowanym od lat sygnale wypiętrzania polodowcowego (GIA, ang. *Glacial isostatic adjustment*) (Cheng et al., 2013). Ponieważ otrzymywane wartości współczynników niskiego rzędu na podstawie danych z misji GRACE są niewystarczająco dokładne, należyte oszacowania $C_{20}, C_{21}, S_{21}, C_{20}$ i S_{21} są uzyskiwane z analizy obserwacji SLR z pięciu satelitów geodezyjnych: LAGEOS-1 i 2 (ang. *Laser Geodynamics Satellite*), Starlette, Stella i Ajisai.

Dane z misji GRACE przetwarzane są w określony sposób według zasad opisanych na poziomach 1 do 3.

- **Poziom 0** - Dane poziomu 0 są wynikiem gromadzenia surowych danych przez centrum operacji (MOS) w Neustrelitz / Niemcy. Wykorzystując anteny śledzące Weilheim (WHM) i Neustrelitz (NST), MOS otrzymuje z każdego satelity GRACE dwa

razy dziennie dane, które są przechowywane w dwóch plikach w archiwum RDC poziomu 0. Dodatkowo, przede wszystkim w celu analizy danych operacyjnych sygnału radiowego, surowe dane są również odbierane podczas każdego przejścia w polarnej satelitarnej stacji odbiorczej GFZ (SRS) w Nowym Alesund (NYA) i przekazywane do GFZ w Poczdamie.

- **Poziom 1** - Udostępniany jest w dwóch wariantach. Produkty danych poziomu 1A są wynikiem przetwarzania zastosowanego do danych poziomu 0. Przeprowadzona zostaje kalibracja, przekształcająca dane w postaci binarnej na dane w jednostkach użytkowych dzięki zastosowanym współczynnikom kalibracyjnym. Tam, gdzie to konieczne, rozwiązuje się drugą niejednoznaczność całkowitą znacznika czasu, a dane są oznaczane czasowo względem odpowiedniego czasu zegara odbiornika satelitarnego. Produkty danych poziomu 1B są wynikiem potencjalnie nieodwracalnego przetwarzania stosowanego zarówno do danych poziomu 1A, jak i poziomu 0. Dane są ponownie oznakowane lub próbkowane do czasu GPS, filtrowane, przefiltrowane na niższą częstotliwość próbkowania i/lub przekształcane na ilości używane w przetwarzaniu poziomu 2. Dane poziomu 1B obejmują pomiary mikrofalowe pasm K/Ka, obserwacje akcelerometru, pozycji wyznaczanej poprzez odbiorniki GPS i kamery śledzącej gwiazdy, a dla misji GRACE-FO również pomiary interferometru laserowego LRI ([Wen et al., 2019](#)).
- **Poziom 2 (Dane wykorzystane w publikacjach [1][2][3])** - Dane pochodzące z tego poziomu to wyestymowane współczynniki harmonicznych sferycznych ziemskiego potencjału grawitacyjnego. Są one udostępniane publicznie dla wszystkich użytkowników w ciągu 60 dni od pozyskania danych. Dane poziomu 2 obejmują dynamiczne (miesięczne i tygodniowe) i statyczne pole grawitacyjne pochodzące ze skalibrowanych i zatwierdzonych produktów danych GRACE poziomu 1B. Poziom ten obejmuje również pomocnicze zestawy danych (np. średnie zmiany masy atmosfery i oceanów), które są niezbędne do interpretacji zmienności czasowej w rozwiązaniach pola grawitacyjnego. Oprogramowanie do przetwarzania poziomu 2 zostało opracowane niezależnie przez wszystkie trzy centra przetwarzania. Rutynowe przetwarzanie odbywa się w UTCSSR (ang. *University of Texas at Austin - Center for Space Research*) i GFZ, podczas gdy JPL generuje produkty poziomu 2 do celów weryfikacji ([Yuan, 2018](#)).
- **Poziom 3 (Dane wykorzystane w publikacjach [4][5])** - Na tym poziomie dostępne są gotowe siatki, przyjazne użytkownikowi do jego własnych opracowań. Transformacja potencjału grawitacyjnego na zmiany mas ziemskich wymaga przeprowadzenia obliczeń w kilku krokach. Trzeba usunąć błędy systematyczne i przy-

padkowe, efekt wypiętrzania izostatycznego GIA, błędy wynikające z falowania mórz i oceanów (wpływ atmosfery jest usuwany w przetwarzaniu produktu na poziomie 2), wykonać rozmycie filtrem o promieniu 300 km dla lądów i 500 km dla oceanów w celu usunięcia artefaktów związanych z inklinacją orbity (ang. *destriping*) oraz wprowadzić poprawkę ze względu na oddzielny wpływ sygnału oceanów i lądów (Cooley, 2021).

Ponieważ wraz z upływem czasu zmieniają się pewne parametry opisujące model statyczny geopotencjału, wedle którego są tworzone rozwiązania miesięczne GRACE należy więc zadać sobie pytanie czy raz przyjęte rozwiązanie jest właściwe? Twórcy misji ciągle starają się ulepszać swoje dzieło i dzięki temu możemy mówić o kolejnych wersjach przetworzonych danych, oznaczonych jako RL01-06. Wczesne produkty RL01-04 zostały zastąpione przez najpierw RL05, a w ostatnim czasie RL06 ze względu na znaczącą redukcję szumów tła. Serie czasowe GFZ RL05 są publikowane od 17 marca 2012 r. i zastąpiły wersję RL04. Modele RL05 zawierają zmiany grawitacyjne spowodowane przez hydrosferę, kriosferę, zdarzenia epizodyczne takie jak duże trzęsienia ziemi, GIA oraz błędy lub niemodelowane efekty zastosowanych modeli tła. Główna różnica w stosunku do RL04 jest taka, że nie zmieniono żadnych współczynników sferycznych harmonicznych C_{20} , C_{30} , C_{40} , C_{21} i S_{21} . Liczba obserwacji i ich spójność spowodowała, że wymienione powyżej współczynniki podczas przeliczania danych RL05 są dokładniejsze niż te same współczynniki wyznaczone alternatywnymi metodami dla RL04. Maksymalny stopień i rozwinięcie współczynników sferycznych harmonicznych n i m dla modeli RL05 został zmniejszony do 90×90 podczas gdy dla (RL04: 120×120). W porównaniu z RL04, obecne szeregi czasowe RL05 wykazują około 2-krotną poprawę pod względem redukcji szumów (Bettadpur, 2007). Rozdzielczość przestrzenna wyznaczenia poszczególnych funkcjonalów na podstawie współczynników sferycznych harmonicznych wzrosła z ok. 525 km (RL04) do ok. 350 km (RL05) (Dahle et al., 2014). Zawartość informacji w plikach GSM RL06 jest taka sama jak w poprzednich plikach GSM RL05. Zmienione zostały model statyczny geopotencjału z GIF48 na GGM05C oraz model pływów z IERS-2003 na IERS-2010. Produkty RL06 GSM mogą być nadal używane w taki sam sposób jak produkty RL05 GSM (Dahle et al., 2013). Misje GRACE/-FO charakteryzują się dużą regularnością dostępności danych. Jednakże wraz z trwaniem pierwszej misji, ze względu na problemy z instrumentami pomiarowymi, pojawiały zaburzenia ciągłości dostarczania danych. Dla misji GRACE brakuje 3 na 105 epok pomiarowych w latach 2002-2010 i 17 z 78 epok w latach 2011-2017. Kolejnym istotnym problemem jest 13 miesięczna przerwa pomiędzy misjami GRACE i GRACE-FO. **W związku z tymi wydarzeniami istotne jest zaproponowanie metod umożliwiających zapewnienie ciągłości modelowania zmienności pola grawitacyjnego na podstawie innych dostępnych obserwacji**

o charakterze globalnym ale opartych na sensoryce nie ilościowej.

Mascon solution to rozwiązanie miesięcznych serii danych z GRACE zaproponowane przez CSR jako alternatywa dla reprezentacji danych poprzez harmoniczne sferyczne. Rozwiązanie ma charakter regularnej siatki, gdzie każdy element to tzw. maskon o promieniu 120km. Maskony są estymowane wedle tych samych standardów co rozwiązanie CSR RL05 rozwinięcia w szereg harmonicznych sferycznych z danych poziomu-1 pozyskanych z misji GRACE. Korzyścią tego rozwiązania jest brak konieczności filtracji sygnału w celu pozbycia się artefaktów (pasków) powstałych ze względu na inklinację orbity satelitów GRACE. Podejście Mascon pozwala również na lepszą separację sygnałów lądowych i oceanicznych (Watkins et al., 2015).

5.2 Przetwarzanie danych AMSR-E

Jak już wspomniano w rozdziale (4.5) instrumenty AMSR są pasywnymi radiometrami mikrofalowymi o podwójnej polaryzacji i skanowaniu stożkowym. Każdy z nich znajduje się na niemal biegunowej orbicie, co umożliwia rejestrację danych w danej lokalizacji na Ziemi nawet dwa razy dziennie. Istotną cechą tych instrumentów AMSR jest zdolność do penetracji chmur, co umożliwia nieprzerwane obserwacje pomiarów, np. oceanu. Produkty poziomu 1 (L1) dla instrumentu AMSR-E są generowane przez Japońską Agencję Badań Kosmicznych (JAXA, ang. *Japan Aerospace Exploration Agency*) i przekazywane do SIPS-RSS (ang. *Science Investigator-led Processing Systems - Remote Sensing System*) w celu przetworzenia na poziom 2A (L2A). Następnie przesyłane są do NASA, do jednostki GHRC DAAC (ang. *Global Hydrometeorology Resource Center Distributed Active Archive Center*), która jest wspólnie zarządzana przez NASA's Marshall Space Flight Center oraz University of Alabama w Huntsville, w celu przetworzenia na poziom 2B (L2B) oraz na poziom 3, zgodnie ze standardem EOS. Te produkty, wraz z metadanymi i powiązaną dokumentacją, są archiwizowane i dystrybuowane przez jednostkę NASA znaną jako NSIDC (ang. *National Snow and Ice Data Center*) (Kawanishi et al., 2003, Njoku et al., 2005, 2003).

Typy udostępnionych danych obejmują dobowe, tygodniowe i miesięczne produkty danych poziomu 1A, poziomu 2A, poziomu 2B i poziomu 3 obejmujące okres od czerwca 2002 r. do początku października 2011 r (Spreen et al., 2008).

- **Poziom 1B (L1B)** - Produkt zawiera dane dotyczące temperatury jasności przeliczonej z temperatury anteny poziomu 1A przy użyciu współczynników konwersji, informacje geometryczne, informacje radiometryczne, rozróżnienie na dane lądowe oraz morskie i dane uzupełniające (GCOM-MAS-100045A, 2013).
- **Poziom 1R (L1R)** - Produkt to ponownie próbkowane dane temperatury jasności

przestrzennie wyznaczone z poziomu 1B, aby dopasować się do środkowej pozycji i rozmiaru pola widzenia każdego pasma częstotliwości w danym pikselu. Temperatura jasności resamplingu jest przetwarzana w celu dopasowania do różnicy rozdzielczości w każdej z zadanych częstotliwości (GCOM-SGC-120011, 2013, Takashi Maeda, 2013).

- **Poziom 2 (L2)** - obejmuje dane fizyczne odtworzone na podstawie temperatury jasności w każdym pikselu. Produkt AMSR-E poziomu 2 przechowuje wielkość geofizyczną obliczoną na podstawie temperatury jasności produktu poziomu 1 oraz informacje geometryczne jako pliki w formacie HDF5. Produkt AMSR-E poziomu 2 to osiem rodzajów geofizycznych danych ilościowych zawierających informacje na temat: całkowitej wody opadowej, chmurowej wody w stanie ciekłym, opadów, temperatury powierzchni morza, prędkości wiatru przy powierzchni morza, koncentracji lodu morskiego, głębokości śniegu, zawartości wilgoci w glebie (GCOM-SGC-120011, 2013, Shibata et al., 2003).
- **Poziom 3 (L3) (Dane wykorzystane w publikacjach [4][5])** - Produkt poziomu 3 zawiera dane globalne, które są dobowymi lub miesięcznymi wartościami średnimi każdej wielkości geofizycznej, takimi jak temperatura jasności w produkcie poziomu 1B i produkcie poziomu 2. Dane na poziomie 3 są obliczane jako średnia dobowa lub miesięczna w każdym kierunku (rosnącym lub malejącym) orbity, a następnie przechowywane w formacie regularnej siatki grid o zdefiniowanej rozdzielczości przestrzennej (Shibata et al., 2003).

Dane pasma L1, L2 to zestawione są w formacie, w którym dane dla każdego śladu orbity przechowywane są w dwuwymiarowej tablicy (punkty obserwacji w kierunku skanowania $\times$ liczba linii skanowania) zgodnie z kolejnością czasu obserwacji. Oprócz danych takich jak temperatura jasności i wartość geofizyczna, w formacie pasma przechowywane są informacje o jakości obserwacji, szerokości geograficznej i długości geograficznej. Standardowe produkty L1B, L1R i L2 przechowywane są w pojedynczym pliku, który obejmuje scenę pokrywającą połowę obwodu Ziemi. Istnieją dwa rodzaje scen: rejestrowana z orbity, wznoszącej od południa do północy i orbity opadającej od północy do południa.

5.3 Opis wykorzystanych danych

W pracy wykorzystano dane pochodzące z pomiarów naziemnych, satelitarnych oraz modeli mieszanych wyszczególnionych w następujących punktach:

Dane pomiary absolutne g (wykorzystane w publikacjach [1][2][5]) - ze stacji grawimetrycznej JOZE znajdującej się w podziemiach budynku Obserwatorium

Astronomiczno - Geodezyjnego w Józefosławiu (Polska), tj. 5.7 m pod ziemią, na betonowym słupie o wymiarach 2×2 m. Pomiary bezwzględne prowadzono w przybliżeniu co miesiąc od maja 2005 r. do listopada 2016 r. grawimetrem FG-5 nr 230. Jest to najdłuższy i jednorodny (zarówno pod względem dokładności, jak i rozdzielczości czasowej) szereg czasowy wartości grawimetrycznych w Polsce. Całkowita niepewność wyznaczania przyspieszenia siły ciężkości wynosiła $\pm 2 \mu\text{Gal}$. Wyniki pomiarów bezwzględnych są korygowane o efekty związane z pływami ziemskimi (model Wenzela).

i pływami oceanicznymi (model FES2004), zmianami ciśnienia atmosferycznego i ruchem biegunów. Ponadto wartości grawitacji są korygowane w rezultacie międzynarodowych kampanii porównawczych. Uwzględniono również czynniki metrologiczne (wynikające ze zmian częstotliwości zegara i lasera). Całość opracowania spełnia wymogi realizacji międzynarodowego układu odniesienia grawimetrycznego (ITGRF, ang. *International Terrestrial Gravity Reference Frame*).

Dane δg GRACE (wykorzystane w publikacjach [1][2]) - do analizy wykorzystano szeregi czasowe dla wybranych miesięcznych rozwiązań misji GRACE opracowanych przez GFZ, CSR i JPL. Dane obejmujące współczynniki sferycznych harmonicznych z rozwiązania RL06 (Dahle et al., 2013) od kwietnia 2002 do marca 2016 roku zostały użyte przy maksymalnym stopniu/rozwinięciu równym 96. Dla danych RL05a wartości wykorzystanych współczynników to: CSR - stopień/rozwinięciu 96, GFZ - 90 i JPL - 90, a dla niektórych rozwiązań aż 60. Na podstawie współczynników sferycznych harmonicznych wyznaczone zostało zaburzenie grawitacyjne oznaczane jako δg . Zaburzenie grawitacyjne rozumiane jest jako różnica między rzeczywistym a normalnym (odnoszącym się do elipsoidy) przyspieszeniem grawitacyjnym na fizycznej powierzchni Ziemi. Zostało to określone na podstawie danych z misji GRACE, uwzględniając elastyczną deformację Ziemi w wyniku obciążenia (Crossley et al., 2012) zgodnie z poniższym wzorem:

$$\delta g_{(\theta, \lambda)} = \frac{GM}{R^2} \sum_{n=0}^{n_{max}} \left(n + 1 - \frac{2h_n}{1 + k_n} \right) \sum_{m=0}^n (\bar{C}_{mn} \cdot \cos(m\lambda) + \bar{S}_{mn} \cdot \sin(m\lambda)) \cdot \bar{P}_{mn} \cos(\theta) \quad (4)$$

gdzie θ, λ to współrzędne sferyczne, h_{nn} i k_{nn} to liczby Love'a odpowiadające całkowitej elastycznej odpowiedzi Ziemi z wykorzystaniem modelu referencyjnego PREM (ang. *Preliminary Earth Model*). Ze względu na korektę parametrów geocentrum na podstawie danych GRACE dla współczynników C_{10} , C_{11} i S_{11} , odpowiadająca wartość k_1 została zmieniona na 0.021. Wartości zaburzenia grawitacyjnego zostały także ustalone za pomocą współczynnika wzmocnienia (Landerer and Swenson, 2012) dla badanego obszaru, który wynosił 1.06. W obszarze przeprowadzonych badań nie zaobserwowano trzęsienia ziemi o magnitudzie powyżej 8.5. Ponadto efekt wynoszenia post lodowcowego jest stosunkowo niewielki. Z tego powodu zdecydowano się nie dokonywać związanych z tym korekt.

Dane TWS (wykorzystane w publikacjach [3][4][5]) - przetworzone dane z misji GRACE, reprezentujące ΔTWS , są dostępne na stronie <https://podaac-tools.jpl.nasa.gov/> i są dystrybuowane przez Centrum Badań Kosmicznych (CSR) w Teksasie. Rozdzielczość przestrzenna danych GRACE użytych w niniejszych badaniach wynosi około $300 \text{ km} \times 300 \text{ km}$. Dane dotyczące zmian masy na powierzchni i w podpowierzchni opierają się na standardzie RL06 (Dahle et al., 2013) na poziomie przetwarzania danych L2. W trakcie przetwarzania danych GRACE współczynnik C_{20} reprezentujący spłaszczenie grawimetryczne Ziemi (Swenson et al., 2008a) został zastąpiony obserwacjami z użyciem techniki Satellite Laser Ranging (SLR) (Cheng and Tapley, 2004), a błąd związany z pasami N-S powstałymi w wyniku inklinacji orbity z został usunięty przy użyciu zmodyfikowanego filtra de-korelacji (Chen et al., 2007) (Swenson and Wahr, 2006). Przy przetwarzaniu danych GRACE została również uwzględniona korekta statycznej części pola grawitacyjnego za pomocą modelu GGM05C (Ries et al., 2016). Podczas przetwarzania danych GRACE współczynniki stopnia 1 (ang. *Geocenter*) były szacowane za pomocą metod przedstawionych w pracach Sun et al. (2016b) i Swenson et al. (2008b) polegających na połączeniu danych GRACE z modelowanym komponentem oceanicznego geocentrum. Korekta spowodowana podnoszeniem izostatycznym lodowców (GIA) została uwzględniona na podstawie modelu ICE6G-D przedstawionego w pracy Peltier et al. (2018).

Dane GLDAS (wykorzystane w publikacjach [1][3]) - Global Land Data Assimilation System to zaawansowany system globalnej asymilacji danych lądowych, który integruje dane meteorologiczne i hydrologiczne z różnych źródeł i modeli w celu generowania kompleksowych zbiorów danych dotyczących cyklu wodnego i innych zjawisk związanych z powierzchnią lądową na całym świecie. GLDAS jest inicjatywą wspólną wielu organizacji, w tym NASA, NOAA, Departamentu Obrony USA oraz Uniwersytetu Maryland, i ma na celu zapewnienie spójnych i dogłębnych danych do badań naukowych dotyczących powierzchni lądowych i klimatu. Modele GLDAS dostarczają wielu istotnych zmiennych hydrologicznych dla terenów lądowych o różnych skalach przestrzennych i czasowych w formie globalnych siatek. Porównania danych z misji GRACE i GLDAS wykazują wysokie zgodności czasowe i niewielkie różnice w amplitudach, co sprzyja korzystaniu z tych danych w globalnych badaniach hydrologicznych (Rodell et al., 2004a,b, Scanlon et al., 2018). Modele GLDAS zapewniają globalne siatki wielu parametrów hydrologicznych lądów w różnych skalach przestrzennych i czasowych. GLDAS obejmuje cztery różne modele powierzchni terenu (LSM, ang. *land surface models*), a mianowicie CLM (ang. *Community Land Model*), Mosaic, Noah oraz VIC (ang. *Variable Infiltration Capacity*) o zmiennej pojemności infiltracyjnej. W pracy [1] wykorzystano cztery modele GLDAS obejmujące okres od stycznia 2002 r. do grudnia 2016 r. Na podstawie tych danych wyznaczono globalne siatki ΔTWS , które są obliczane przy użyciu składników wyjściowych

dotyczących średniej wilgotności warstwy gleby, całkowitego ekwiwalentu wody w koronie drzew i ekwiwalentu wody w pokrywie śnieżnej z każdego LSM. Zmiany TWS uzyskuje się przez usunięcie długookresowej średniej z każdej miesięcznej siatki ΔTWS . Następnie zmiany ΔTWS są przeliczane na współczynniki zmiany masy $\Delta \hat{C}_{n,m}^{hydr}$, $\Delta \hat{S}_{n,m}^{hydr}$ używając analizy harmonik sferycznych i dalej współczynników Stokes'a za pomocą wzorów (Wahr et al., 1998):

$$\begin{Bmatrix} \Delta C_{n,m}^{hydr} \\ \Delta S_{n,m}^{hydr} \end{Bmatrix} = \frac{3\rho_w}{\rho_{ave}} \frac{1+k'}{2n+1} \begin{Bmatrix} \Delta \hat{C}_{n,m}^{hydr} \\ \Delta \hat{S}_{n,m}^{hydr} \end{Bmatrix} \quad (5)$$

gdzie ρ_w i ρ_{ave} oznaczają odpowiednio przeciętną gęstość wody i Ziemi. Bazując na wynikach z pracy [1] w pracy [3] miesięczne rozwiązania GLDAS-Noah (v2.1) o rozdzielczości przestrzennej wynoszącej $1^\circ \times 1^\circ$ (zbiór danych: GLDAS-NOAH10-M) zostały pobrane z witryny Earth Data NASA <https://disc.gsfc.nasa.gov/> i obejmowały okres od stycznia 2002 do stycznia 2021 roku. Do badań wykorzystano 34 parametry opisane w dokładnie w pracy [3].

Dane SM (wykorzystane w publikacjach [4][5]) - zbiór danych AMSR-E jest dostępny jako pliki o charakterystyce dobowych pomiarów na <https://disc.gsfc.nasa.gov/>. AMSR-E/Aqua surface SM descending V002 to zestaw danych poziomu 3 (w formie siatki) z dobową częstotliwością i rozdzielczością przestrzenną około 25 km na 25 km. Pomiarzy SM powierzchni lądu pochodzą z pasywnych danych z teledetekcji mikrofalowej i są obliczane przy użyciu modelu LPRM. LPRM opiera się na modelu transferu promieniowania w przód, aby uzyskać SM przypowierzchniowej warstwy gleby i głębokość optyczną penetracji sygnału. AMSR-E na satelicie NASA EOS Aqua zaprzestał dostarczania danych w październiku 2011 z powodu problemu z obrotem jego anteny (van der Vliet et al., 2020), co uniemożliwiło dostarczanie dłuższego ciągu pomiarowego. W przeprowadzonych badaniach wykorzystano tylko orbity opadające ze względu na znacznie lepszą stabilność nocnej temperatury gleby, pokrycia roślinnością i powietrza (De Jeu et al., 2008, Draper et al., 2009, Liu et al., 2012, 2011, Owe et al., 2001). Przepływ danych został wskazany na rysunku (6)

5.4 Normalizacja i skalowanie czasowo-przestrzennych danych dotyczących ΔTWS

Dane miesięczne rozwiązania pochodzące z misji GRAE ograniczone są przez stosunkowo niską rozdzielczość przestrzenną. W celu uzyskania bardziej szczegółowych i lokalnych informacji o zmianach ilości wody, naukowcy stosują techniki skalowania (ang. *downscaling*). Te techniki wykorzystują dodatkowe dane i modele matematyczne, aby rozszerzyć możliwość wykorzystania danych z misji GRACE na mniejszą skalę przestrzenną. W ten sposób można uzyskać bardziej szczegółowe dane o zmianach ilości wody na mniejszych

obszarach. (Miro and Famiglietti, 2018, Seyoum et al., 2019, Vishwakarma et al., 2021b, Wilby et al., 1998, Wilby and Wigley, 1997, Yin et al., 2018).


Możemy wyszczególnić kilka podejść do tego zagadnienia, takich jak:

- Modelowanie hydrologiczne (**Publikacje [1][2]**), w którym wykorzystuje się modele hydrologiczne, które integrują dane o opadach, parowaniu, odpływie powierzchniowym i zasobach wód podziemnych, aby uzyskać bardziej szczegółowe informacje w skali lokalnej. Modele te wykorzystują dane z GRACE do skalowania i dostosowania wyników do lokalnych warunków (Döll et al., 2014).
- Metody interpolacji (**Publikacje [3][4][5]**), które wykorzystują dodatkowe dane przestrzenne, takie jak dane z czujników glebowych, stacji meteorologicznych, obserwacji hydrologicznych, aby interpolować dane z GRACE na obszary wymagające większej szczegółowości stosując przykładowo metody krigingu, metody wielomianowe czy wzmocniony filtr Kalmana (Eicker et al., 2014).
- Synergia danych wielosensorowych (**Publikacje [4][5]**) - możliwe jest wykorzystanie danych z innych źródeł, takich jak dane z sensorów teledetekcyjnych, danych z sondowania glebowego, aby wzbogacić dane z GRACE i uzyskać bardziej szczegółowe informacje w przypadku mniejszych obszarów (Dee et al., 2011, Jackson et al., 1981).
- Metody uczenia maszynowego (**Publikacja [3][5]**) - wykorzystanie technik uczenia maszynowego, takich jak sieci neuronowe, algorytmy regresji, może pomóc w dokładniejszym przekształceniu danych z GRACE na dane o większej szczegółowości i zrozumieniu lokalnych wzorców zmian ilości wody (Long et al., 2014, Seyoum and Milewski, 2017).

5.5 Konieczność i sposoby filtracji obserwacji GRACE i GRACE-FO

Źródło błędu, którego charakterystyczną sygnaturą są paski N-S, jest obecne w danych GRACE i GRACE-FO na niższych poziomach przetwarzania. Przykład zaszumionych i odfiltrowanych danych przedstawiono na rysunku (4). Swenson i Wahr zaobserwowali szczególną właściwość sferycznych współczynników harmonicznych związanych z rozkładem przestrzennym i zaprojektowali klasę filtrów, aby usunąć problem (Swenson and Wahr, 2006). W celu redukcji szumów obserwacyjnych stosuje się wygładzanie przestrzenne w postaci filtru Gaussa (**Publikacje [1][2]**). Nie jest to jednak idealna metoda. Zaproponowana przez J.Kusche dekorrelacja bazująca na założeniu a'pori dotyczącym budżetu błędów została sprawdzona na podstawie walidacji modeli hydrologicznych (Kusche

et al., 2009). Podobne rozwiązanie zaproponowano ostatnio przy użyciu pełnej informacji kowariancyjnej (Horvath et al., 2018). Dobrym rozwiązaniem okazały się filtry nieizotropowe (Chen et al., 2006, Kusche, 2007) (Publikacje [2][3][4][5]), które umożliwiły stosowanie produktów poziomu 2 z jak najwierniej zachowaną informacją geofizyczną. Z biegiem czasu filtry DDK1-8 stały się podstawowym narzędziem stosowanym przy opracowywaniu danych. Problemem jest jednak to, że nie określono, który spisuje się najlepiej. Jakość stosowanego rozwiązania będzie zależała od szerokości geograficznej obszaru opracowania oraz mocy danego filtra. Im niższy numer, tym większa siła filtracji. Pojawiały się także próby optymalizacji efektu związanego z filtracją i gubieniem sygnału geofizycznego (Dutt Vishwakarma et al., 2016), jednakże dobór filtra na danym obszarze nadal ma charakter empiryczny i zależy od prowadzonego badania.



Rysunek 4: Przykład zaszumionych (a) i odfiltrowanych (b) danych GRACE. Zmiana undulacji geoidy w mm, policzona dla danych GRACE z marca 2002 r. na podstawie danych RL06 opublikowanych przez CSR dla stopnia rozwinięcia $n = 90$. Źródło: Opracowanie własne.

5.6 Metody dekompozycji sygnału LSSA i STL

W literaturze opisywane są różne podejścia i metody dotyczące dekompozycji sygnału szeregów czasowych. Można wyróżnić najpopularniejsze metody takie, jak: metody średniej ruchomej, procedury X-11, dekompozycja sygnału bazująca na falkach (ang. *Wavelet Transform*), empiryczna dekompozycja modalna - EMD (ang. *Empirical Mode Decomposition*), dekompozycja na składowe harmoniczne wykorzystujące transformację Fouriera, SEATS (ang. *Seasonal Extraction in ARIMA Time Series*) czy też redukcja wymiarów za pomocą analizy głównych składowych PCA (ang. *Principal Component Analysis*) (Cleveland and Tiao, 1976, Singh et al., 2017, West, 1997). LSSA (ang. *Least-Squares Spectral Analysis*) (Vaníček, 1969, 1971) (Publikacje [1][2]) jest metodą estymacji widma, która

polega na dopasowywaniu sinusoid o znanych okresach do obserwowanych danych. Metoda ta pozwala na identyfikację dominujących częstotliwości w sygnale czasowym. Kluczowym punktem metody LSSA jest dopasowanie sinusoid o znanych okresach do danych przy użyciu technik najmniejszych kwadratów. Metoda ta pozwala na estymację amplitud i faz tych sinusoid, które najlepiej dopasowują się do sygnału.

$$Y_s(t) = a + bt + c_s \cos\left(\frac{2\pi t}{T_s}\right) + d_s \sin\left(\frac{2\pi t}{T_s}\right) \quad (6)$$

gdzie: a jest wyrazem wolnym, b trendem długoterminowym C_s i d_s to współczynniki wag składowych cosinusowych i sinusowych, a T_s odpowiada za użytą okresowość. Ze względu na cykliczny charakter obserwacji zmian pola siły ciężkości Ziemi, w badaniach wykorzystane zostały składowe fale rocznych i półrocznych do dekompozycji sygnału. Wartości współczynników wyznaczono za pomocą metody najmniejszych kwadratów:

$$\hat{x} = (A^T A)^{-1} A^T y \quad (7)$$

gdzie: $\hat{x}$ to wektor poszukiwanych parametrów wpasowania funkcji okresowych, y to wykorzystane obserwacje funkcji celu w zależności od jednostki czasu, a macierz A to układ równań składowych okresowych dla danych jednostek czasu.

STL (ang. *seasonal trend decomposition*) (Cleveland et al., 1990) (Publikacja [1]) jest nieparametryczną metodą dekompozycji szeregów czasowych na składnik sezonowy $S(t)$, składnik trendu $T(t)$ i składnik reszty $R(t)$ opisywaną wedle wzoru:

$$Y_s(t) = S(t) + T(t) + R(t) \quad (8)$$

STL wykonuje się iteracyjnie w kolejnych krokach, usuwając długookresowy trend liniowy, wyznaczając na podstawie lokalnej regresji komponenty sezonowe. Następnie oblicza się zrekonstruowany i wygładzony sygnał sezonowy przy użyciu filtrowania dolnoprzepustowego. W kolejnym kroku wykonuje się różnicę wyznaczonych sygnałów sezonowych względem obserwowanego i powtarza procedurę do uzyskania kryterium dla zbieżności komponentów sezonowych $S(t)$ i składnika trendu $T(t)$. STL ma potencjał identyfikowania możliwych wartości odstających w danych poprzez włączenie wag odporności dla każdego pomiaru do procedury opartej na filtrowaniu regresji ważonej lokalnie (He et al., 2022, Theodosiou, 2011).

5.7 Określenie metod i kryteriów porównawczych oraz miar jakości pomiędzy analizowanymi zbiorami danych

Analizy porównawcze wymagają dobrania odpowiednich miar jakości, pozwalających ocenić, jak dobrze model lub zbiór danych odzwierciedla rzeczywiste dane. Wybór odpowiednich miar zależy od rodzaju analizy i charakterystyki danych, które są porównywane.

W pracy zostały zastosowane miary jakości takie, jak: efektywność Nasha-Sutcliffe’a (NSE) (Nash, 1970), współczynnik korelacji Pearsona (CC) (Cohen et al., 2009), test Kolmogorova-Smirnova (KS) (Hodges Jr, 1958), błąd średniokwadratowy ($RMSE$, RMSE (ang. *root mean square error*)) (Chai and Draxler, 2014) oraz znormalizowany błąd średniokwadratowy ($NRMSE$), a także korelacja krzyżowa ($xcorr$) i współczynnik determinacji (R^2) (Nagelkerke et al., 1991).

NSE (Publikacja [3][5]) jest znormalizowaną statystyką określającą względną wielkość resztkowej wariancji (szumu) w porównaniu do wariancji danych pomiarowych (informacji). NSE jest obliczany za pomocą następującego wzoru:

$$NSE = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_{i,sim})^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (9)$$

gdzie: n oznacza liczbę obserwacji, y_i to wartość rzeczywista obserwacji i , $\hat{y}_{i,sim}$ to wartość przewidywana przez model dla obserwacji i , $\bar{y}$ to średnia wartość ze wszystkich obserwacji.

Test KS (Publikacja [3]) sprawdza, czy dwie próbki pochodzą z tego samego rozkładu. Ta statystyka mierzy maksymalną odległość (supremum) między dystrybuantami kumulacyjnymi (CDF , (ang. *Cumulative Distribution Function*)) dwóch próbek. Rozkład jest zakładany jako ciągły. Jeśli statystyka KS jest mała lub wartość p jest wysoka, nie możemy odrzucić hipotezy, że rozkłady dwóch próbek są takie same. Współczynnik KS jest obliczany za pomocą następującego wzoru:

$$KS = \sup |F(x) - G(x)| \quad (10)$$

gdzie: $F(x)$ to dystrybuanta kumulacyjna dla jednej z próbek, $G(x)$ to dystrybuanta kumulacyjna dla drugiej próbki, $\sup$ oznacza supremum, czyli maksymalną wartość bezwzględną różnicy między dystrybuantami $F(x)$ i $G(x)$ w całym zakresie zmiennej x .

Wartość KS wskazuje na największą odległość między dystrybuantami kumulacyjnymi próbek $F(x)$ i $G(x)$. Im większa wartość KS , tym większa różnica między rozkładami próbek, co sugeruje mniejsze podobieństwo między nimi. Metoda ta jest metodą nieparametryczną, co oznacza, że nie wymaga założeń dotyczących rozkładu danych. Może być stosowany zarówno do danych o rozkładzie normalnym, jak i niestandardowym, co czyni go wszechstronnym narzędziem do analizy różnorodnych typów danych. Test KS ma wysoką czułość na nawet niewielkie różnice w kształcie lub parametrach rozkładów dwóch zbiorów danych. Dzięki temu pozwala on wykrywać nawet subtelne zmiany w rozkładach, co jest istotne w wielu badaniach naukowych, gdzie istotne są nawet niewielkie odchylenia od oczekiwań. Metoda może być stosowany do różnych rozmiarów próbek oraz różnych typów danych, w tym do danych ciągłych, dyskretnych oraz zmiennych czasowych. Dzięki temu nadaje się do szerokiego zakresu zastosowań, a prostota interpretacji i informacja o istotności różnic daje szerokie spektrum możliwości użycia zapewniając wysoką ufność do wyników.

Współczynnik korelacji Pearsona (CC) (**Publikacje [1][2][3][4]**) jest obliczany za pomocą następującego wzoru:

$$CC = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} \quad (11)$$

gdzie: n oznacza liczbę obserwacji, x_i i y_i to odpowiednio wartości zmiennych x i y dla obserwacji i , $\bar{x}$ i $\bar{y}$ to średnie wartości zmiennych x i y .

Współczynnik korelacji Pearsona mierzy stopień liniowej zależności między zmiennymi x i y . Jego wartość mieści się w zakresie od -1 do 1, gdzie wartość 1 oznacza doskonałą dodatnią liniową zależność, wartość -1 oznacza doskonałą ujemną liniową zależność, a wartość 0 oznacza brak liniowej zależności między zmiennymi. Im bliżej wartości CC jest do 1 (lub -1), tym silniejsza jest zależność między zmiennymi. Metoda ta zakłada liniową zależność między zmiennymi i może nie wykrywać innych rodzajów związków, takich jak nieliniowe lub niemonotoniczne relacje. Ponadto, korelacja Pearsona może być wrażliwa na wartości odstające oraz na niestandardowe rozkłady danych. W niektórych sytuacjach inne metody, takie jak korelacja rang Spearmana lub korelacja tau Kendalla, mogą być bardziej odpowiednie do analizy związków między zmiennymi. Jednakże, ze względu na skuteczność w wykrywaniu liniowych zależności między zmiennymi w kontekście przeprowadzanych badań zdecydowano się na tą metodę.

Współczynnik $RMSE$ (**Publikacje [2][3][5]**) jest obliczany za pomocą następującego wzoru:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (12)$$

gdzie: n oznacza liczbę obserwacji, y_i to wartość rzeczywista obserwacji i , $\hat{y}_i$ to wartość przewidywana dla obserwacji i przez model.

$RMSE$ jest miarą odchylenia między wartościami rzeczywistymi y_i a wartościami przewidywanymi przez model $\hat{y}_i$. Im mniejsza wartość $RMSE$, tym lepiej model odwzorowuje rzeczywiste dane.

Współczynnik $NRMSE$ (**Publikacje [3][5]**) jest obliczany za pomocą następującego wzoru:

$$NRMSE = \frac{RMSE}{\max(y) - \min(y)} \quad (13)$$

gdzie: $RMSE$ to pierwiastek błędu średniokwadratowego, $\max(y)$ to największa wartość w zbiorze rzeczywistych danych y , $\min(y)$ to najmniejsza wartość w zbiorze rzeczywistych danych y .

W kontekście analizy danych GRACE mamy do czynienia z amplitudą zjawiska na danym obszarze. Współczynnik $NRMSE$ jest miarą odchylenia między wartościami przewidywanymi przez model a rzeczywistymi danymi, znormalizowaną do zakresu wartości danych. Dzięki temu można porównywać wartości $NRMSE$ dla różnych zbiorów

danych o różnych zakresach wartości. Im mniejsza wartość $NRMSE$, tym lepiej model odwzorowuje rzeczywiste dane, niezależnie od ich zakresu wartości.

Wzór na korelację krzyżową (**Publikacje [2][4]**) między dwiema seriami czasowymi $x(t)$ i $y(t)$ wygląda następująco:

$$xcorr_{xy}(\tau) = \frac{\sum_{t=1}^{N-\tau} (x(t) - \bar{x})(y(t + \tau) - \bar{y})}{\sqrt{\sum_{t=1}^{N-\tau} (x(t) - \bar{x})^2 \sum_{t=1}^{N-\tau} (y(t + \tau) - \bar{y})^2}} \quad (14)$$

gdzie: N - liczba punktów w serii czasowej, τ - opóźnienie (time lag) między seriami czasowymi, $x(t)$ - wartość w czasie t w pierwszej serii czasowej, $y(t + \tau)$ - wartość w czasie $t + \tau$ w drugiej serii czasowej, $\bar{x}$ - średnia wartość w pierwszej serii czasowej ($\bar{x} = \frac{1}{N} \sum_{t=1}^N x(t)$), $\bar{y}$ - średnia wartość w drugiej serii czasowej ($\bar{y} = \frac{1}{N} \sum_{t=1}^N y(t)$).

Korelacja krzyżowa pozwala określić jakie jest wzajemne opóźnienie między dwiema seriami czasowymi oraz w jakim stopniu są one skorelowane w tych opóźnieniach. Wartość korelacji krzyżowej $xcorr_{xy}(\tau)$ jest bliska 1, jeśli istnieje silna korelacja między seriami czasowymi przy opóźnieniu τ , bliska -1, jeśli istnieje silna korelacja ujemna, oraz bliska 0, jeśli brak jest korelacji.

Współczynnik R^2 (**Publikacja [5]**) reprezentuje jak dobrze model wyjaśnia wariancję zmiennej zależnej.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (15)$$

gdzie: n oznacza liczbę obserwacji, y_i to rzeczywista wartość obserwacji i , $\hat{y}_i$ to przewidywana wartość dla obserwacji przez model, $\bar{y}$ to średnia wartość wszystkich obserwacji.

R^2 jest miarą oceniającą, jak dobrze model regresji dopasowuje się do danych. Wartość R^2 mieści się w przedziale od 0 do 1, gdzie 1 oznacza idealne dopasowanie modelu do danych. Wyższa wartość R^2 sugeruje lepsze dopasowanie modelu do danych. Współczynnik efektywności modelu Nasha-Sutcliffe'a jest zbliżony do współczynnika determinacji, różniąc się głównie zastosowaniem. R^2 służy jako wskaźnik jakości dopasowania statystycznego modelu. W przeciwieństwie do tego, NSE służy do kwantyfikowania zdolności modelu do prognozowania zmiennej wynikowej. Podczas gdy R^2 znajduje szerokie zastosowanie we różnych dziedzinach do oceny ogólnego dopasowania modelu do obserwowanych danych, NSE stosuje się w hydrologii i naukach środowiskowych, koncentrując się na ocenie dokładności modelu w prognozach.

Aby przeprowadzone analizy mogły identyfikować wyniki jako rzetelne, należy wyznaczyć minimalną liczbę próbek danych potrzebną do ustalenia istotności statystycznej. Badania oparte na danych GRACE mają charakter czasowo-przestrzenny. Decydując się na eksperymenty w ujęciu czasowym należy pamiętać, że w przypadku podejścia czasowego, agregacja danych dla każdej zlewni rzecznej znacznie zmniejsza wielkość próbki, co może podważać poprawność porównania. Aby móc wnioskować, że porównanie A/B ma

sens, konieczne jest ustalenie minimalnej liczby próbek włączonych do zbioru testowego (Ioannidis, 2005). W celu zaobserwowania zmiany obserwowanych efektów na poziomie 1% - 2% między wynikami, zakładając 95% poziom ufności i 80% moc testu, ustalono wielkość efektu, a następnie obliczono minimalną liczbę próbek potrzebną do oceny w prowadzonych badaniach.

5.8 Transformacje liniowe sygnału ΔTWS za pomocą EOF

Dane pochodzące z misji GRACE wymagają przestrzennego wygładzenia sygnału. Wykorzystanie intensywnie uśredniających filtrów przestrzennych o dużym promieniu wygładzenia prowadzi do utraty sygnału geofizycznego, znanego jako „błąd wycieku danych” (ang. *leakage error*) (Longuevergne et al., 2010, Swenson and Wahr, 2002). Filtrowanie zmniejsza rozdzielczość przestrzenną obserwacji GRACE, utrudniając identyfikację sygnału masy wody w głównym strumieniu sygnału. Analiza EOF (**Publikacja [4]**) to metoda analizy danych o charakterystyce czasowo-przestrzennej służąca do oddzielania sygnałów od szumu sygnału. Jest to korzystne w przypadkach takich jak problemy z utratą sygnału geofizycznego przy zmniejszającej się rozdzielczości przestrzennej podczas filtracji (Wouters and Schrama, 2007). Metoda EOF w pierwszym kroku wymaga obliczenia macierzy kowariancji dla danych przestrzennych, które zawierają pomiary w różnych punktach przestrzeni. Załóżmy, że mamy dane przestrzenne o wymiarze $n \times m$, gdzie n to liczba punktów w przestrzeni, a m to liczba czasowych pomiarów. Oznaczmy macierz danych jako X , gdzie X_{ij} to wartość zmiennej w i -tym punkcie przestrzennym w j -tym kroku czasowym:

$$C_{ij} = \frac{1}{m} \sum_{j=1}^m X'_i \cdot X_j \quad (16)$$

gdzie X'_i to wektor zawierający wartości zmiennej w i -tym punkcie przestrzennym dla wszystkich kroków czasowych, a sumowanie odbywa się dla wszystkich j od 1 do m . W kolejnym kroku obliczane są wektory własne (ang. *eigenvectors*) V i odpowiadające im wartości własne (ang. *eigenvalues*) λ macierzy kowariancji C . Wektory własne V są rozwiązaniami równania:

$$C \cdot V = \lambda \cdot V \quad (17)$$

Następnie wybierana jest określona liczba k -EOF, które odpowiadają największym wartościom własnym λ . Wybrane wektory własne reprezentują główne składowe, które wyjaśniają największą wariancję w danych. Na podstawie wybranych EOF obliczane są wzorce przestrzenne (ang. *spatial patterns*) i wzorce czasowe (ang. *time series*). Wzorce przestrzenne wzorce $PC_i(x, y)$ pokazują jak zmieniają się dane w przestrzeni i są obliczane ze wzoru:

$$PC_i(x, y) = \sum_{j=1}^n V_{ij} \cdot X_j(x, y) \quad (18)$$

gdzie sumowanie odbywa się dla wszystkich j od 1 do n . $X_j(x, y)$ to wartość zmiennej w punkcie (x, y) przestrzeni, a V_{ij} to i -ty element wybranego wektora własnego V . Wzorce czasowe $T_i(t)$ pokazują jak zmieniają się dane w czasie i są obliczane ze wzoru:

$$T_i(t) = \sum_{j=1}^n V_{ij} \cdot X_i(t) \quad (19)$$

gdzie sumowanie odbywa się dla wszystkich j od 1 do n . $X_i(t)$ to wartość zmiennej w kroku czasowym t , a V_{ij} to i -ty element wybranego wektora własnego V .

Metoda ta umożliwia identyfikowanie i analizę dominujących wzorców zmienności w danych przestrzennych, co pozwala na wyodrębnienie informacji o głównych tendencjach i amplitudach charakteryzujących badane zjawiska.

5.9 Analiza maksymalnej kowariancji

Jak wspomniano w rozdziale (4.7) istnieją techniki, które do analizy biorą pod uwagę zarówno przestrzenne, jak i czasowe aspekty danych ΔTWS i wilgotności gleby, na przykład TSA (Martínez-Fernández and Ceballos, 2005, Wang et al., 2018), TC (ang. triple collocation) (Crow et al., 2015, Gruber et al., 2017, Hasan and Tarhule, 2021, Yin and Park, 2021) oraz empiryczne funkcje ortogonalne EOF (ang. *Empirical Orthogonal Functions*) (Eom et al., 2017, Lei et al., 2012, Navarra and Simoncini, 2010, Schrama et al., 2007, Yoo and Kim, 2004).

Analiza maksymalnej kowariancji (MCA, ang. *Maximum Covariance Analysis*) (**Publikacja** [4]) jest techniką analizy wielowymiarowej, która służy do identyfikacji współzmiennych wzorców w dwóch zbiorach danych. Metoda ta izoluje najbardziej spójne pary wzorców przestrzennych i związanych z nimi szeregów czasowych, przeprowadzając analizę wartości własnych macierzy kowariancji czasowej między dwoma obszarami geofizycznymi (Von Storch and Zwiers, 2002).

Zastosowanie tej metody jest uzasadnione w przypadku porównywania danych mikrofalowych o większej rozdzielczości przestrzennej i większej częstotliwości czasowej pomiarów niż grawimetryczne pomiary satelitarne. Rozważając EOF standardowego MCA (Rieger et al., 2021), amplituda przestrzenna (As) umożliwia zrozumienie, które regiony mają największy udział w danym modzie. Amplitudę przestrzenną można łatwo obliczyć za pomocą zespolonego EOF i zespolonego sprzężonego EOF*:

$$As = \sqrt[2]{EOF \times EOF^*} \in \mathbb{C} \quad (20)$$

Określenie w jaki sposób poszczególne regiony są ze sobą dynamicznie powiązane możliwe jest poprzez wyznaczenia przesunięcia fazowego za pomocą następującego równania:

$$\theta = \tan\left(\frac{\mathbb{R}(EOF)}{\mathbb{I}(EOF)}\right)^{-1} \quad (21)$$

Dzięki zastosowaniu tej metody możliwa jest identyfikacja dominujących wzorców zmienności między zbiorami danych X i Y , a także zrozumienie związków i współzależności między różnymi zmiennymi w tych zbiorach.

5.10 Metody rekonstrukcji sygnału ΔTWS przy użyciu metod bazujących na uczeniu maszynowym

W uczeniu maszynowym istnieje kilka rodzajów problemów, w których można zastosować te algorytmy. Są to zadania takie jak klasyfikacja, regresja, analiza skupień, wykrywanie obiektów, prognozowanie, rekomendacja czy wykrywanie anomalii. Rekonstrukcję sygnału można rozwiązać za pomocą modelowania regresji przy użyciu algorytmów uczenia maszynowego. Problem regresji można określić jako przewidywanie ciągłej zmiennej wynikowej na podstawie danego zestawu predyktorów (lub cech). Model regresji to technika tworzenia równania matematycznego definiującego y jako funkcję zmiennych X . Regresja liniowa jest najprostszą i najbardziej popularną techniką przewidywania zmiennej ciągłej wyznaczanej według wzoru:

$$Y = X\beta_1 + \beta_0 + \epsilon \quad (22)$$

gdzie: β_0 jest wyrazem wolnym, β_1 jest wagą lub współczynnikiem regresji związanym ze zmienną predykcyjną (cechą lub atrybutem) X , a ϵ jest szumem Gaussa.

Współczesne metody uczenia maszynowego, takie jak maszyny wektorów nośnych (SVM ang. *Support Vector Machines*), drzewa decyzyjne, czy sztuczne sieci neuronowe (ANN) mają znacznie większą zdolność do modelowania bardziej skomplikowanych zależności w danych. Modele te cechują się zdolnością do wykrywania nieliniowych zależności, co jest szczególnie ważne w kontekście rekonstrukcji sygnałów, które często mają złożoną i nieregularną strukturę. W przypadku rekonstrukcji sygnałów czasowych używa się różnych technik regresji, takich jak regresja liniowa, regresja wielomianowa, regresja grzbietowa (ang. *ridge regression*), czy regresja oparta na drzewach decyzyjnych. Innym podejściem, szczególnie użytecznym w przypadku danych sekwencyjnych, jest wykorzystanie modeli autoregresyjnych. Modele autoregresyjne to modele, w których wartości sygnału są estymowane na podstawie wcześniejszych wartości tego samego sygnału. Popularnym przykładem jest model autoregresyjny ARIMA (ang. *AutoRegressive Integrated Moving Average*) (Box and Pierce, 1970), który łączy autoregresję i skumulowaną średnią ruchomą.

W dzisiejszych czasach wiele metod rekonstrukcji sygnału wykorzystuje sztuczne sieci neuronowe (Seyoum et al., 2019), szczególnie sieci rekurencyjne (RNN, ang. *Recurrent Neural Network*) (Zaremba et al., 2014) i sieci splotowe (CNN) (Kattenborn et al., 2021). Sieci RNN są szczególnie przydatne w analizie sekwencji, takich jak sygnały czasowe, ponieważ mogą przechowywać informacje o poprzednich stanach i wykorzystywać je do prognozowania kolejnych wartości sygnału. Sieci CNN są stosowane do analizy danych przestrzennych, takich jak obrazy, ale mogą być również użyteczne w przypadku analizy sygnałów o strukturze przestrzennej, takich jak dźwięki lub fale. Jedną z kluczowych kwestii w regresji jest walidacja modelu, czyli sprawdzenie, jak dobrze model radzi sobie z prognozowaniem wartości sygnału na nowych danych, które nie były użyte w procesie treningu. Dzięki odpowiedniej walidacji, możemy ocenić skuteczność modelu i określić jego dokładność w przewidywaniu nowych wartości sygnału.

Bazując na wcześniejszych badaniach dotyczących porównywania modeli wydajnościowych oraz skupiając się na złożoności i interpretowalności modeli, zdecydowano się na wykorzystanie w przeprowadzonych badaniach (**Publikacja [3][5]**) modelu XGBoost (Chen and Guestrin, 2016). XGBoost Regressor to zaawansowana metoda wzmacniania gradientowego, która wykorzystuje drzewa decyzyjne jako słabe modele predykcyjne. Cały proces trenowania XGBoost Regressor można podzielić na kilka kroków:

1. Inicjalizacja modelu:

$$F_0(x) = 0 \quad (23)$$

2. Obliczenie residułów:

$$r_i = y_i - F_{k-1}(x_i) \quad (24)$$

3. Budowa drzewa k:

$$T_k(x) = \sum_{j=1}^J c_{ij} \cdot I(x \in R_{ij}) \quad (25)$$

$$F_k(x) = F_{k-1}(x) + \nu \cdot T_k(x) \quad (26)$$

gdzie: k - numer drzewa (k -ty krok) c_{ij} - wartość węzła j w liściu R_{ij} $I(x \in R_{ij})$ - wskaźnik, który jest równy 1, gdy x należy do liścia R_{ij} , w przeciwnym razie 0, ν - współczynnik uczenia (learning rate), który kontroluje wpływ nowego drzewa na model.

4. Mechanizm regularyzacji:

$$\text{cel} = \sum_{i=1}^n L(y_i, F_k(x_i)) + \sum_{j=1}^J \Omega(c_j) \quad (27)$$

gdzie: L - funkcja straty, która mierzy błąd predykcji Ω - funkcja regularyzacji, która ogranicza złożoność drzewa.

5. Optymalizacja celu:

$$c_j = \arg \min_{c_j} \left[\sum_{x_i \in R_{ij}} L(y_i, F_{k-1}(x_i) + c_j) + \Omega(c_j) \right] \quad (28)$$

6. Zatrzymanie budowy drzew: Proces budowy drzew jest powtarzany, aż zostaną spełnione warunki zatrzymania, np. osiągnięcie maksymalnej liczby drzew lub osiągnięcie minimalnej głębokości drzewa.

7. Predykcja: Po zakończeniu trenowania, model jest gotowy do dokonywania predykcji na nowych danych. Predykcja dla nowego przypadku x jest obliczana jako suma predykcji wszystkich drzew w modelu:

$$\hat{y} = F_K(x) = F_0(x) + \nu \sum_{k=1}^K T_k(x) \quad (29)$$

gdzie: x - wektor cech pojedynczego przypadku y - rzeczywista wartość dla tego przypadku $F_k(x)$ - predykcja modelu na k -ty krok $T_k(x)$ - predykcja k -tego drzewa c_j - wartość węzła j w liściu R_{ij} R_{ij} - obszar węzła j w k -tej iteracji Ω - funkcja regularyzacji, która ogranicza złożoność drzewa ν - współczynnik uczenia (ang. *learning rate*), który kontroluje wpływ nowego drzewa na model K - liczba drzew w modelu L - funkcja straty, która mierzy błąd predykcji.

Użycie modelu XGBoost zezwala na interpretowalność zależności między cechami a funkcją celu. Explainable Artificial Intelligence (XAI) to podejście w dziedzinie sztucznej inteligencji, które ma na celu uczynienie procesów podejmowania decyzji przez modele uczenia maszynowego bardziej zrozumiałymi i interpretowalnymi dla ludzi. W tradycyjnych modelach uczenia maszynowego, takich jak głębokie sieci neuronowe, drzewa decyzyjne czy lasy losowe, działanie modelu może być często trudne do zrozumienia, ponieważ te modele są złożone i składają się z tysięcy parametrów. W kontekście zastosowań praktycznych, np. w medycynie, finansach czy przemyśle, zrozumienie jak model dokonuje swoich predykcji jest kluczowym elementem, szczególnie jeśli te predykcje mają wpływ na ludzkie życie i podejmowanie ważnych decyzji. Dlatego właśnie metody XAI stają się coraz bardziej istotne, ze względu na eksplikację wyznaczonych wag predykatów w odniesieniu do zmiennej przewidywanej, co nazywane jest interpretowalnością modelu (Breiman, 2001, Elith et al., 2008, Fisher et al., 2019, Friedman, 2001).

Inną metodą zezwalającą na interpretowalność relacji pomiędzy cechami jest metoda SHAP (ang. *SHapley Additive exPlanations*) (Lundberg and Lee, 2017) (Publikacja [3]). Jest oparta na teorii gier i wykorzystuje wartości Shapleya, które są używane do oceny wkładu poszczególnych graczy w zyski lub straty w grach kooperacyjnych. W przypadku analizy cech w modelach uczenia maszynowego, wartości Shapleya są używane do określenia istotności cech w przewidywaniach modelu. Załóżmy, że mamy model uczenia maszynowego, który przewiduje wynik $f(x)$ dla danej instancji x z wektorem cech $x = (x_1, x_2, \dots, x_n)$. Wartość SHAP dla cechy x_i dla instancji x jest obliczana jako różnica między przewidywaną wartością dla całej instancji $f(x)$ a przewidywaną wartością, gdyby cecha x_i została pominięta, oznaczoną jako $f(x_{\sim i})$. Wzór na wartość SHAP dla

cechy x_i dla instancji x można zapisać jako:

$$\phi_i(x) = f(x) - f(x_{\sim i}) \quad (30)$$

Następnie, aby uzyskać istotność cechy x_i w całym modelu, oblicza się średnią wartość SHAP dla tej cechy dla wszystkich instancji w zbiorze danych, stosując formułę:

$$\bar{\phi}_i = \frac{1}{N} \sum_{j=1}^N \phi_i(x^{(j)}) \quad (31)$$

gdzie N to liczba instancji w zbiorze danych, a $x^{(j)}$ to j -ta instancja.

Metoda SHAP pozwala na zrozumienie, jakie cechy mają największy wpływ na przewidywania modelu, a także na wyjaśnienie, dlaczego model dokonuje określonych predykcji. Jest to szczególnie przydatne w interpretacji modeli złożonych, które są trudne do zrozumienia tylko na podstawie wag cech. Dzięki metodzie SHAP możemy lepiej zrozumieć, jakie czynniki wpływają na decyzje modelu i dlaczego dana instancja została zaklasyfikowana w określony sposób.

W pracy (**Publikacja [5]**) wykorzystano kilka popularnych algorytmów do modelowania problemów regresji. Wybór algorytmów regresji do tego badania pokierowany był ich ustaloną skutecznością w analizie zróżnicowanych zbiorów danych i cech oraz ich przydatnością do modelowania badanego zjawiska. Na podstawie wcześniejszych badań ([Bonaccorso, 2018](#), [Doan and Kalita, 2015](#), [Maulud and Abdulazeez, 2020](#)), które oceniły różne algorytmy uczenia maszynowego do zadań regresji, zidentyfikowano kilka popularnych metod ze względu na ich stabilne wyniki przy różnych charakterystykach danych. Wybrane algorytmy obejmują różnorodne podejścia, począwszy od metod zespołowych, takich jak las losowy i drzewa losowe, znane ze zdolności do uchwycenia złożonych zależności w dużych zbiorach danych, po algorytmy wzmacniania gradientu, które wyróżniają się w obsłudze danych o wysokiej wymiarowości i osiągnięciu lepszej dokładności predykcyjnej. Random Forest Regressor ([Grömping, 2009](#)) to wszechstronna metoda zespołowa wykorzystująca wiele drzew decyzyjnych do stworzenia stabilnego modelu predykcji, znana ze swojej dokładności i odporności na nadmierne dopasowanie. Extra Trees Regressor ([Geurts et al., 2006](#)) jest podobny do Random Forest, ale stosuje bardziej losowy sposób wyboru punktów podziału węzłów, co zwiększa różnorodność i potencjalnie poprawia generalizację. K Neighbors Regressor ([Cover and Hart, 1967](#)) to metoda nieparametryczna przewidująca wartość zmiennej docelowej na podstawie średniej k najbliższych punktów danych. Light Gradient Boosting Machine (LightGBM) ([Ke et al., 2017](#)) to framework wzmacniania gradientu zaprojektowany pod kątem efektywności i szybkości, odpowiedni dla dużych zbiorów danych i zdolny do obsługi cech kategorycznych. Decision Tree Regressor ([Xu et al., 2005](#)) to model drzew decyzyjnych, który dzieli dane na homogeniczne segmenty, co pozwala na interpretację, ale może prowadzić do nadmiernego dopasowania.

Gradient Boosting Regressor ([Friedman, 2002](#)) to algorytm, który iteracyjnie dopasowuje drzewa decyzyjne do reszt poprzedniego drzewa, tworząc stabilny model predykcyjny. Regresja liniowa to proste, liniowe podejście modelowania relacji między zmiennymi docelowymi a predyktorami za pomocą równania liniowego. Least Angle Regression (LARS) ([Efron et al., 2004](#)) to technika regresji, która identyfikuje najbardziej istotne predyktory, zachowując interpretowalność poprzez stopniowe wybieranie cech. Bayesian Ridge to metoda regresji oparta na analizie bayesowskiej, która oszacowuje parametry modelu, równoważąc złożoność modelu i jakość dopasowania. Ridge Regression ([McDonald, 2009](#)) to regresja liniowa z regularyzacją L2, która redukuje problemy wieloliniowości i stabilizuje oszacowania parametrów. Huber Regressor ([Sun et al., 2020a](#)) to technika regresji odporna na obserwacje odstające, minimalizująca wpływ odstających obserwacji przy zachowaniu dokładnych predykcji. Orthogonal Matching Pursuit ([Tropp and Gilbert, 2007](#)) to metoda selekcji modeli rzadkich, która sekwencyjnie wybiera zmienne najbardziej skorelowane z zmienną docelową. Lasso Regression ([Hans, 2009](#)) to metoda regresji liniowej z regularyzacją L1, odpowiednia do selekcji cech i tworzenia rzadkich modeli. Elastic Net ([Li and Lin, 2010](#)) łączy metody regularyzacji L1 (Lasso) i L2 (Ridge), zapewniając elastyczne podejście do regresji. Lasso Least Angle Regression (LARS Lasso) to metoda łącząca algorytm LARS z regularyzacją L1, tworzącą interpretowalny i oszczędny model. Dummy Regressor ([Angrist, 2001](#)) to podstawowy model służący jako punkt odniesienia do oceny wydajności innych modeli regresji, zwykle dokonujący predykcji na podstawie średniej lub mediany zmiennej docelowej. AdaBoost Regressor ([Solomatine and Shrestha, 2004](#)) wykorzystuje adaptacyjne boostingowanie do poprawy wydajności predykcji słabego modelu regresji, koncentrując się na punktach danych z większymi błędami predykcji. Passive Aggressive Regressor ([Segal, 2004](#)) to wariacja algorytmu pasywno-agresywnego dostosowana do zadań regresji, która dostosowuje parametry modelu, gdy zaobserwowane są błędy.


6 Syntetyczny opis wyników badań

6.1 Publikacja [1]

Kuczynska-Siehlen, J., Piretzidis, D., Sideris, M. G., Olszak, T. and Szabó, V. (2019) ‘*Monitoring of extreme land hydrology events in central Poland using GRACE, land surface models and absolute gravity data*’, Journal of Applied Geodesy, Vol. 13, No. 3, pp.229–243, doi: 10.1515/jag-2019-0003.

100 pkt MEiN; IF: 1.30

Publikacja [1] stanowi szczegółowe studium wariacji przyspieszenia siły ciężkości Ziemi wyznaczonych metodami grawimetrycznych pomiarów absolutnych, satelitarnych i globalnych modeli numerycznych. Celem badań, stanowiących przedmiot publikacji była analiza zgodności wyznaczenia zmienności pola grawitacyjnego oraz lokalnych warunków, w których zbieżność obserwacji jest największa. Rozdział 2.1.2 (z opisywanej publikacji) opisuje wpływ lokalnych efektów na pomiar wartości przyspieszenia. Lokalne warunki pomiarowe mają duże znaczenie na wyznaczaną wartość „ g ” i mogą prowadzić do błędnych interpretacji, dlatego ważnym procesem było uwzględnienie do opracowania obserwacji poprawki wynikającej z topografii, struktur urbanistycznych związanych z kształtem i wielkością budynku, redukcji położenia grawimetru FG5 ze względu na położenie słupa pomiarowego poniżej poziomu gruntu oraz zmian wynikających z tzw. efektu parasola (ang. *umbrella effect*) polegającego na spływie wody opadowej po dachu budynku obserwatorium tworzącego rozkład przestrzenny wód opadowych wokół punktu pomiarowego. Rysunki od 3 do 6 (z opisywanej publikacji) pokazują wpływ przestrzenny i czasowy opisywanych efektów. Ze względu na specyfikę położenia grawimetru pokazaną na rysunku 7 (z opisywanej publikacji) poprawna interpretacja pomiarów możliwa jest jedynie przy dokładnym zamodelowaniu geologicznej struktury i hydrologicznych efektów w danym regionie pomiarów. Poprawkę ze względu na tzw. płytę Bouguer’a odpowiadającą z usunięciem mas wystających ponad punkt pomiarowy oraz lokalny efekt hydrologiczny przeprowadzono zgodnie ze schematem przedstawionym we wzorach 2-8 (z opisywanej publikacji). Do wyznaczenia zaburzenia grawimetrycznego z misji GRACE użyto rozwiązań CSR i JPL rozwiązań RL06 opracowanych zgodnie z opisem w rozdziale 2.2 (z opisywanej publikacji) oraz zaprezentowanym na rysunku nr (5).



Rysunek 5: Schemat wyznaczenia zaburzenia grawimetrycznego z pomiarów misji GRACE. Źródło: Opracowanie własne.

Sprężysta reakcja stałej Ziemi na topnienie mas lodowych z ostatniego maksimum lodowcowego nie będzie miała znaczącego wpływu na analizowany obszar badań, dlatego korekta izostaticzna nie została uwzględniona, podobnie jak zniekształcenia sygnału wywołane trzęsieniami ziemi. Do badań użyto modelu GLDAS z czterech symulacji Noah, CLM, VIC, Mosaic, dzięki którym wyznaczono hydrologiczny komponent odpowiadający sumie średniej zawartości wody w glebie, roślinności oraz opadach śniegu. Kluczową częścią badań było usunięcie z obserwowanych sygnałów części związanej z trendem liniowym oraz sezonową i sub-sezonową cykliczną cyrkulacją wodną. Zamodelowanie tych efektów przeprowadzono na podstawie złożenia funkcji trygonometrycznych i wyznaczenia współczynników algorytmami STL oraz LSSA. Przeprowadzona została analiza korelacji, na podstawie której zbadano zgodności badanych sygnałów. Główne wyniki przeprowadzonych badań przedstawiono w tabeli 1 (z opisywanej publikacji). Ponieważ na okres obserwacji składały się takie wydarzenia, jak intensywne opady powódź hydrogeologiczna, fale gorąca oraz susza analiza zbieżności sygnałów była podzielona na poszczególne okresy.

W przeprowadzonych badaniach byłem odpowiedzialny między innymi za przygotowanie danych z misji GRACE polegającym na napisaniu skryptu umożliwiającego filtrowanie danych współczynników sferycznych harmonicznych poziomu 2 filtrami nie-

izotropowymi DDK1-8. Stanowiło to motywację do pogłębienia tematu i przeprowadzenia prac badawczych w kontekście synergii relacji pomiędzy danymi pochodzącymi z różnych sensorów a jakością wyników uzyskiwanych ze względu na konwolucję zbiorów danych. Wstępne opracowanie danych misji GRACE stanowi kluczowy element prac badawczych i stało się niezbędnym elementem każdego przeprowadzonego procesu badawczego w poszczególnych publikacjach.

Wartościowymi wnioskami z powyższego badania wartymi odnotowania są:

- Dotkliwość i zasięg powodzi w 2010 r. w Europie Środkowej są wyraźnie zauważalne, co skutkuje anomaliasi zmiany grawitacji $3,5\text{--}14\text{ }\mu\text{Gal}$ w zależności od źródła danych. Ujemne anomalie zmiany grawitacji rzędu $2,5\text{--}5\text{ }\mu\text{Gal}$ są również identyfikowane i powiązane z odnotowanymi warunkami suszy. Uzyskane wyniki sugerują, że metody monitorowania zmian pola grawitacyjnego stanowią realną metodę identyfikacji klimatologicznych zdarzeń ekstremalnych w skali regionalnej.
- Analiza korelacji pokazuje zgodność między danymi pomiarowymi z grawimetru, GRACE i GLDAS na poziomie 0.7-0.9. Korelacja zwiększa się, gdy wykorzystywane są skorygowane dane grawimetru, co wskazuje, że metoda usuwania lokalnego wpływu hydrologicznego z pomiarów grawimetru jest wiarygodna. Zwiększoną korelację uzyskuje się również, gdy analizę przeprowadza się tylko dla lat 2009–2012 okres, który obejmuje ekstremalną powódź w 2010 r. i 2011 r. wywołaną ponadprzeciętnymi opadami. Sygnał sezonowy jest usuwany za pomocą LSSA i STL, przy czym obie metody dają porównywalne wyniki. W większości przypadków STL tworzy szeregi czasowe z nieznacznie większą korelacją niż LSSA.
- Susza z 2015r. jest widoczna we wszystkich trzech zestawach danych. W szeregach czasowych grawimetrów obserwuje się gwałtowny spadek grawitacji, od $2\text{ }\mu\text{Gal}$ w czerwcu do $-2,5 \pm 2\text{ }\mu\text{Gal}$ w sierpniu i $-2,3 \pm 2,3\text{ }\mu\text{Gal}$ we wrześniu. Stosunek sygnału do szumu dla pomiarów grawimetrycznych w tym samym okresie jest bliski lub równy jeden, co czyni je statystycznie nieistotnymi dla monitorowania tego zdarzenia. W badanym szeregu czasowym uzyskanym z misji GRACE występuje ujemna anomalia przez cały rok 2015. Extrema anomalii osiągają swoje minimum we wrześniu z wielkością $-5 \pm 1\text{ }\mu\text{Gal}$. Uśrednione szeregi czasowe GLDAS pokazują również ujemne anomalie w zmianach przyspieszenia siły ciężkości w tym okresie.
- Model GLDAS Noah LSM generuje najwyższe anomalie zmiany grawitacji przy $5\text{ }\mu\text{Gal}$ w czerwcu 2010 i $7\text{ }\mu\text{Gal}$ w lutym 2011. Zauważalne jest również przesunięcie fazowe w globalnym maksimum między grawimetrem FG5 a danymi GRACE oraz

GLDAS wynoszące do 3 miesięcy co może być tłumaczone prędkością przesłania wody opadowej pomiędzy kolejnymi warstwami wodonośnymi.

6.2 Publikacja [2]

Szabó, V. and Marjańska, D. (2020) ‘*Accuracy analysis of gravity field changes from GRACE RL06 and RL05 data compared to in situ gravimetric measurements in the context of choosing optimal filtering type*’, Artificial Satellites: Journal of Planetary Geodesy, Vol. 55, No. 3, pp.100–117, doi: 10.2478/arsa-2020-0008.

70 pkt MEiN; IF: 0.90

W publikacji [2] rozważono wartości różnic zaburzenia grawimetrycznego pomiędzy naziemnymi absolutnymi pomiarami grawimetrycznymi oraz przefiltrowanymi danymi GRACE uzyskanymi z ośrodków CSR, JPL i GFZ. Celem prac było oszacowanie różnic pomiędzy sposobami filtracji miesięcznych rozwiązań pochodzących z reporocessingu RL06 i RL05 misji GRACE. Konieczność filtracji danych GRACE wynika z zależności pomiędzy architekturą orbity i częstotliwością pomiarów objawiającą się w postaci pewnego rodzaju błędu w obserwacjach. Dokładność poszczególnych rozwiązań oceniono na podstawie absolutnych pomiarów grawimetrycznych wykonanych grawimetrem FG5 nr 230 w latach 2002-2016. Przygotowana publikacja obejmuje dwie zasadnicze części. W pierwszej przeanalizowano różnice pomiędzy sposobem filtracji danych na podstawie różnic we współczynnikach sferycznych harmonicznym. Druga to część eksperymentalna zawierająca opracowanie danych naziemnych z pomiarów grawimetrycznych i piezometrycznych oraz satelitarnych. Źródło błędu przedstawione zostało na rysunku 1 (z opisywanej publikacji), w którym zaprezentowano symulację ścieżek orbit badanych satelitów wskazującą na konieczność interpolacji danych, których brakuje dla części obszarów. Ze względu na inklinację orbity wynoszącą 89.5° mamy do czynienia z akumulacją danych w regionach polarnych i spadkiem liczby obserwacji w okolicach równikowych. Wynika z tego konieczność wprowadzenia metod matematycznych umożliwiających jak najwierniejsze odzwierciedlenie sygnału fizycznego wraz ze zmieniającą się szerokością geodezyjną. W publikacji zaprezentowano filtrację charakterystycznych północno-południowych pasków na podstawie wzorów (1-6) (z opisywanej publikacji) oraz wskazano na różnice wynikające z zadeklarowanego promienia rozmycia w zależności od stopnia rozwinięcia sferycznych harmonicznym z danego modelu geopotencjału, który przedstawia rysunek nr 2 (z opisywanej publikacji). Kolejną badaną metodą był zbiór filtrów nieizotropowych DDK. Istotą tego rozwiązania jest zmiana okna równoleżnikowego szerokości filtru w zależności od szerokości geodezyjnej. Różnice pomiędzy różnymi filtrami zostały zaprezentowane za pomocą metryki pierwiastka kwadratowego stopnia wariancji sferycznych harmonicznym, którą przedstawiono na rysunku nr 6

(z opisywanej publikacji). Wykresy wskazują na większą stabilność filtrów DDK dla wyższych stopni rozwinięcia współczynników sferycznych harmonicznych. Wskazane zostały również różnice pomiędzy RL06 i RL05, gdzie można zauważyć niewielkie rozbieżności do stopnia 60 dla filtrów typu DDK. Lepszą kompatybilność pomiędzy RL06 i RL05 zachowują filtry Gaussa o promieniach 500 i 600km, podczas gdy w przypadku filtrów anizotropowych kompatybilność wykazują typy DDK 1–4. W publikacji schemat eksperymentu przedstawia rysunek 7 (z opisywanej publikacji). Dane pochodzące z pomiarów naziemnych i satelitarnych zostały opracowane zgodnie z metodyką opisaną w podrozdziale 3.1 (z opisywanej publikacji). Ze względu na intensywne opady w okresie 2010-2011, mające bezpośredni efekt w postaci powodzi hydrologicznej na badanym obszarze, ważnym krokiem było wyznaczenie poprawki ze względu na ten hydrologiczny efekt, która została uwzględniona w procesie przetwarzania danych grawimetrycznych. Wyniki korekty wprowadzonej zgodnie ze wzorem (7) (z opisywanej publikacji) zostały przedstawione na rysunku nr 9 (z opisywanej publikacji). Porównanie pomiędzy danymi z sensorów satelitarnych i naziemnych wykonano przeliczając potencjał grawitacyjny na funkcjonal zaburzenia grawitacyjnego opisanego równaniem (8) (z opisywanej publikacji). Ponieważ dane GEACE charakteryzują się dużą sezonowością w celu poprawnego porównania sensorów zdecydowano się wykluczyć cykliczne efekty (roczne, półroczne i kwartalne) zmian amplitud w zarejestrowanych obserwacjach GRACE. Efekt ten zamodelowany został poprzez wpasowanie funkcji sinusoidalnych, których współczynniki wyznaczono metodą Gaussa-Markowa. Tak zdekomponowany sygnał porównany został na rysunkach 11 i 12 (z opisywanej publikacji), gdzie przedstawiono odpowiednio średnie zaburzenie grawimetryczne wraz z odchyleniem standardowym wynikającym z filtracji oraz obserwacje rezydualne. Analizę dokładności przeprowadzono w wykorzystaniu błędu pierwiastka średniokwadratowego oraz korelacji krzyżowej. Uzyskane wyniki zaprezentowano w tabeli 1 (z opisywanej publikacji).

Głównymi wnioskami z przeprowadzonych eksperymentów badawczych są:

- Zmiana poziomu wód gruntowych z -11 m do -8 m może być widoczna z pułapu satelitów grawimetrycznych.
- Usunięcie z szeregów czasowych zjawisk okresowych zmian grawitacji związanych z różnymi porami roku umożliwiło badanie lokalnych zmian środowiska. W przypadku filtracji Gaussa najlepsze wyniki uzyskano przy promieniu wygładzania równym 300 km, co jest zgodne z zaleceniami oficjalnych ośrodków przetwarzania danych. Inne promienie wykorzystywane do tego rodzaju filtracji powodują zbyt duże uśrednianie danych na badanym obszarze.
- Biorąc pod uwagę najnowszy przetworzony zestaw danych GRACE, filtry DDK3–DDK6

opublikowane przez CSR i JPL charakteryzują się wysokim współczynnikiem korelacji krzyżowej na poziomie 0.8 i zadowalającym RMSE w zakresie 3.7–4.0 μGal , czyli mniejszym niż dwukrotność niepewności wykonanego pomiaru przez grawimetr FG5. Dla tych samych filtrów w wersji danych RL05a wszystkie trzy centra obliczeniowe cechują dobre wyniki zarówno dla współczynnika korelacji krzyżowej, jak i RMSE, przy wartościach odpowiednio 0.7–0.8 lub 4.1–4.7 μGal . Odpowiednio przefiltrowane obserwacje satelitarne zarejestrowane przez misję GRACE mogą być z powodzeniem stosowane w badaniach w Obserwatorium Astronomiczno-Geodezyjnym w Józefosławiu Politechniki Warszawskiej (JOZE).

- Poprawna selekcja strategii przetwarzania satelitarnych danych grawimetrycznych jest niezwykle istotna. W wersji RL06 dla rozwiązań GFZ po dekompozycji sygnału uzyskane rezultaty charakteryzowały się generalnie słabszym dopasowaniem do pomiarów naziemnych. Co więcej filtry DDK1-2 dają zbyt intensywne rozmycie sygnału geofizycznego i mogą być stosowane tylko na dużych obszarach oceanicznych lub w analizie szeregów czasowych dla całych dorzeczy.
- Obserwacje satelitarne wykonane przez misję GRACE odpowiednio przefiltrowane mogą być z powodzeniem stosowane w badaniach w obserwatorium JOZE oraz do wzmocnienia realizacji IGRF na punktach na których nie wykonuje się obserwacji grawimetrycznych.

6.3 Publikacja [3]

Szabó, V. (2022) ‘*Comparison features importance for temporal and spatial-temporal approaches in GRACE and GRACE-FO signal reconstruction based on GLDAS data*’, International Journal of Hydrology Science and Technology, doi: 10.1504/IJHST.2022.10048532
100 pkt MEiN; IF: 1.80

W publikacji [3] zaprezentowano nowe podejście do selekcji parametrów fizycznych uwzględnianych w modelu hydrologicznym do rekonstrukcji sygnału ΔTWS przy użyciu metod bazujących na uczeniu maszynowym (ang. *machine learning*). Jak wspomniano około roczna przerwa pomiędzy istnieniem misji GRACE i GRACE-FO ujawniła potrzebę odtworzenia obserwacji ΔTWS na podstawie innych danych. Rosnąca w ostatnich latach moc obliczeniowa komputerów wskazała na zainteresowanie naukowców algorytmami uczenia maszynowego oraz sztucznych sieci neuronowych (ANN). W wielu pracach naukowcy przyjmują całkowity ekwiwalent wodny jako uproszczoną sumę zasobu wód podziemnych, lądowych, śnieżnych oraz przypowierzchniową wodę rozumianą jako parametr wilgotności gleby. Wartości tych cech fizycznych z powodzeniem są modelowane numeryczne poprzez

wieloczynnikowe modele hydrologiczne. Jednakże proces obiegu wody jest bardziej skomplikowany, a nowe techniki obliczeniowe umożliwiają uzyskanie dokładnego odtworzenia sygnału na podstawie wielu parametrów fizycznych. W publikacji [3] zaproponowano dwa podejścia do wskazywania różnic w istotności użytych cech przy rekonstrukcji sygnału ΔTWS , oddzielnie dla podejścia czasowego i przestrzenno-czasowego. Schemat eksperymentu i obszar badań przedstawiają odpowiednio rysunek 1 oraz 2 (z opisywanej publikacji). Ze względu na ideę porównania dwóch sposobów prowadzenia analiz danych GRACE w podziale na analizy regionalnych efektów w obrębie danych dorzeczy oraz poszczególnych punktów rozmieszczonych w regularnej siatce, wyznaczona została niezbędna liczba danych do uzyskania istotności statystycznej umożliwiającej wyciągnięcie prawidłowych wniosków na poziomie ufności $> 95\%$. Bazując na doświadczeniach i wynikach z publikacji [1] zdecydowano się na użycie danych z modelu GLDAS-NOAH jako danych, które posłużyły do rekonstrukcji sygnału. Dane ΔTWS RL06 dostarczane przez ośrodek CSR zostały oznaczone jako cel rekonstrukcji i przetworzono je przy użyciu filtracji DDK2 na podstawie doświadczeń i wyników zaprezentowanych w publikacji [2]. Dane prezentujące poszczególne parametry fizyczne zawarte w modelu GLDAS zostały poddane wstępnej selekcji i standaryzacji zgodnie z opisem w podrozdziale 2.4 (z opisywanej publikacji). Do wyznaczenia współczynników w modelu funkcji regresji algorytmu XGBoost. Jakość rozwiązania oceniono na podstawie metryk RMSE, NRMSE, CC, NSE, i KS. Osiągnięte metryki odpowiadają wynikom prezentowanym w pracach innych naukowców. Wartości metryk globalnych oraz mapy zawierające charakterystyki przestrzenne dokładności rozwiązania zaprezentowano odpowiednio w tabeli 2 oraz na rysunku 6 (z opisywanej publikacji). Wyniki modelowania były zawałające, co pozwoliło na przejście do właściwej części eksperymentu, w której wyznaczono istotność użytych cech. W rozdziale 3.2 (z opisywanej publikacji) zaprezentowano podejścia do wyznaczania istotności parametrów za pomocą modelowo-agnostycznej wersji ważności cech oraz objaśnienia addytywnego Shapleya (SHAP), metod popularnie używanych w dziedzinie wytłumaczalnej sztucznej inteligencji (XAI).

Z przeprowadzonego badania można wysnuć kilka istotnych wniosków:

- Rekonstrukcja sygnału ΔTWS za pomocą metod uczenia maszynowego charakteryzuje się dużą skutecznością i mogą one być alternatywą dla stochastycznych podejść takich jak Ensemble Kalman filter.
- Wielowymiarowa kombinacja dużych zbiorów danych umożliwia uzyskanie dobrych rezultatów w kontekście rekonstrukcji sygnału ΔTWS charakteryzujących się błędem RMS z zakresu 4.2–5.0 cm oraz współczynnikiem $NSE > 0.7$.

- Nie można jednoznacznie wyznaczyć zmiennych o największym wpływie na modelowanie sygnału ΔTWS , ale można zaobserwować zależność dla pewnej grupy zmiennych, w skład której wchodzi: zawartość wody w warstwie śnieżnej, wilgotność gleby na wszystkich warstwach oraz spływ podpowierzchniowy.
- Każde z podejść ukazuje wyraźny wpływ zmiennych związanych z czasem, położeniem i wilgotnością. Wskazuje to na związek z monotoniczną naturą zjawiska i jego dużą zależnością od przynależności do danych stref klimatycznych.
- Niezwykle istotnym parametrem okazał się spływ podpowierzchniowy. Jednakże brak możliwości zdefiniowania kompleksowych warunków jak spękana warstwa wodonośna podłoża skalnego, wysoka zawartość gliny lub kamienia może prowadzić do przeszacowywania tej zmiennej przez model. Kompleksowe badanie zależności dynamiki ΔTWS od stanu podpowierzchniowego za pomocą pomiarów grawimetrycznych wskazało na silniejszy związek między współczynnikiem odpływu a zmianą ΔTWS niż obserwowany przy pomiarach wilgotności w przypowierzchniowej warstwie gleby.
- Na podstawie istotności cech wyznaczonej poprzez algorytm SHAP można stwierdzić stosunkowo niewielkie znaczenie wody zawartej w roślinności wykorzystywanej jako cecha do rekonstrukcji sygnału ΔTWS .
- Najniższą dokładność statystyk prezentującą dokładność rekonstrukcji sygnału ΔTWS uzyskano w rejonach rzeki Parana w południowych rejonach Ameryki Południowej, rzeki Saskatchewan-Nelson i St. Lawrence w rejonie Wielkich Jezior na pograniczu Kanady i USA, Huang He (Rzeka Żółta), Amur, Liao we wschodniej części kontynentu azjatyckiego oraz obszarów pokrywających się z terenami Sahary. Wiąże się to z dużą zależnością modelu od predyktorów związanych z SM oraz brakiem uchwycenia zależności antropogenicznych spowodowanych brakiem występowania takich zmiennych.
- Wielkość dorzeczy ma znaczenie dla modelu, jednakże nie stwierdzono istnienia relacji pomiędzy powierzchnią dorzeczy a dokładnością predykcji ΔTWS zwracanych przez model, także implikuje to wniosek, iż nie można odrzucić hipotezy mówiącej o zależności pomiędzy powierzchnią dorzecza a dokładnością rekonstrukcji sygnału.
- Agregacja zmiennych w ujęciu czasowym według wielkości dorzecza wpływa na zmianę wag przypisanych poszczególnym zmiennym w porównaniu z podejściem przestrzenno-czasowym. Jednak zmiana ta dla najbardziej wpływowych zmiennych pozostaje stosunkowo niewielka.

6.4 Publikacja [4]

Szabó, V. Osińska-Skotak, K. (2023) *'Similarities and differences in the Earth's water variations signal provided by GRACE and AMSR-E observations using Maximum Covariance Analysis at various Land Cover data backgrounds'*, Artificial Satellites: Journal of Planetary Geodesy, Vol. 58, No. 2 - 2023, doi: 10.2478/arsa-2023-0006

70 pkt MEiN; IF: 0.90

Publikacja [4] skupia się na problematyce związanej z wodą i jej dystrybucją w przypowierzchniowych warstwach gleby w kontekście porównania obserwacji SM uzyskanych na podstawie misji AMSR-E z obserwacjami ΔTWS z misji GRACE. Wyniki prezentowane w publikacji [3] wskazywały na znaczną wagę w modelowaniu kwestii przepływu wody z płytszych warstw wodonośnych do głębszych. Ze względu na znaczenie badań dotyczących zasobu wód podziemnych modelowanych na podstawie danych GRACE konieczne jest zbadanie warunków, dla których wariancja wilgotności gleby odejmowana w równaniu wyznaczającym GWST jest zgodna z monotonicznością grawimetrycznych obserwacji satelitarnych. W publikacji [4] porównano obserwacje z misji GRACE z mikrofalowymi danymi dobowymi zebranymi przez misję AMSR-E. Badanie przedstawia analizę zgodności obserwacji grawimetrycznych z pasywnymi obserwacjami mikrofalowymi. Aby zachować spójność obserwacji w zakresie częstotliwości i rozdzielczości przestrzennej, dane dotyczące wilgotności z AMSR-E zostały uśrednione na epoki obserwacji misji GRACE, a następnie przeinterpolowane przestrzennie wielomianem 1 stopnia na siatkę obserwacji GRACE o wymiarach $0.5^\circ \times 0.5^\circ$. W publikacji podzielono badania na dwa etapy: analizy globalne i regionalne. W pierwszej części porównano znaczenie klimatu w wyznaczanych parametrach. W badaniu zastosowano analizę maksymalnej kowariancji (MCA), aby wyodrębnić składowe główne dla sygnałów ΔTWS i SM. Analiza została przeprowadzona dla obszaru globalnego, a dyskusję podzielono na poszczególne kontynenty. Podobieństwa i różnice w wynikach zgodności sygnałów przedstawiono w zestawieniu do danych dotyczących pokrycia terenu, które zostały zaprezentowane na rysunku 1 (z opisywanej publikacji). Do analizy wykorzystano dane dotyczące pokrycia terenu pochodzące z zharmonizowanej światowej bazy danych o glebie (ang. Harmonized World Soil Database) przedstawiające pokrycie terenu roślinnością, dostępność tlenu w strefach korzeniowych, tereny uprawne i tereny zurbanizowane. Wykresy 2 i 3 (z opisywanej publikacji) prezentują zagregowane średnie wartości parametrów ΔTWS i SM pochodzące z zakresu mikrofalowego C i X względem współrzędnych geodezyjnych. Wyznaczone zostały także przeciętne wartości anomalii i ich odchylenia standardowe zagregowane względem szerokości geodezyjnej i czasu. Zaprezentowano je na rysunku 4 (z opisywanej publikacji).

Uwidoczniona została anomalia TWSA i SMA z lat 2009-2011 dla szerokości 0-20°S, co może wskazywać na znaczącą zbieżność sygnałów w tych obszarach. Natomiast na szerokościach 20-40°N obserwujemy znaczącą anomalię TWSA, która nie została wychwycona przez sensory AMSR-E. Ponieważ mamy do czynienia z różnymi amplitudami w zjawiskach obserwowanych przez badane sensory, do przeprowadzenia wolumetrycznej analizy podobieństwa zastosowano normalizację wartości do zakresu 0-1 zgodnie ze wzorem (1) (z opisywanej publikacji). Znormalizowane obserwacje ΔTWS i SM pochodzące z zakresu mikrofalowego C i X zaprezentowano, zestawiając wolumen zawartości wody dla czterech pór roku, na rysunku 5 (z opisywanej publikacji). Uzupełniając zestawienie przeprowadzono analizę korelacji sygnałów, przedstawioną na rysunku 6 (z opisywanej publikacji), która wskazuje na dużą wzajemną zgodność sygnałów w rejonach międzyzrotnikowych i brak tej zgodności w rejonach okołobiegunowych. W następnych krokach, w celu określenia obszarów do szczegółowego porównania, amplitudy sygnałów grawimetrycznych i mikrofalowych obliczono za pomocą złożonej empirycznej funkcji ortogonalnej (EOF) i sprzężonej z nią EOF* zgodnie ze wzorami (6) i (7) (z opisywanej publikacji). W efekcie prowadzonych analiz wyprowadzono globalny wniosek o braku zależności sygnałów rejestrowanych przez sensory GRACE i AMSR-E na obszarach wiecznej zmarzliny. Sensory mikrofalowe nie będące wrażliwymi na zmiany w ekwiwalencie śniegu charakteryzuje duży szum obserwacyjny w tych obszarach, podczas gdy GRACE rejestruje zmiany masy wynikające ze zmiany pokrywy lodowej.

Druga część artykułu obejmuje analizy regionalne dla wyselekcjonowanych dóbr. Wyznaczone zostały współczynniki korelacji Pearsona oraz korelacji krzyżowej uwzględniającej maksymalnie 6-miesięczne przesunięcie fazowe pomiędzy sygnałami, które zostały zaprezentowane na rysunkach 10 i 11 (z opisywanej publikacji). Analizy regionalne przeprowadzono dla największych rzek ze wszystkich kontynentów, zapewniając różnorodność pokrycia terenu, warunków klimatycznych w celu wyeliminowania stronniczości we wnioskowaniu. Na rysunku 12 (z opisywanej publikacji) przedstawiono szeregi czasowe ΔTWS i SM oraz ich anomalie dla wybranego zestawu danych, a następnie przeprowadzono dyskusję otrzymanych wyników.

Na podstawie przeprowadzonego badania wyszczególnić można następujące wnioski:

- Naturalnie zalesione obszary i duże otwarte przestrzenie wykorzystywane w rolnictwie przyczyniają się do wzrostu zgodności sygnałów między obserwacjami GRACE i AMSR-E, co wskazuje na istotność parametru dotyczącego warunków tlenu w strefach korzeniowych gleby.
- Istniejące ograniczenia glebowe, takie jak wieczna zmarzlina, znacznie eliminują użyteczność obserwacji mikrofalowych w zakresie X i C. Analizy przeprowadzone w sub-

polarnych regionach za pomocą sensorów grawimetrycznych będą charakteryzowały się przewagą w stosunku do pasywnych obserwacji mikrofalowych.

- Regiony o dużej wariancji sygnału uśrednionego na obszarze całego dorzecza mogą powodować utratę części sygnału geofizycznego, co zaobserwowano i opisano na przykładzie rzeki Zair.
- Przywołane przykłady w podrozdziale dla Europy wskazują na różnice między GRACE i AMSR-E, prowadzący do wniosku o niekorzystnych warunkach wynikających z ograniczeń glebowych i znacznej urbanizacji obszaru.
- Zrozumienie ograniczeń wpływających na szybkość wykrywania zmian i spójność w obserwacjach prowadzonych przy użyciu różnych metod i czujników ma wymierny wpływ na jakość dostarczanych rozwiązań do predykcji geozagrożeń.
- Synergia pomiarów ΔTWS i SM może zapewnić lepsze i wysokiej rozdzielczości zrozumienie procesów na Ziemi związanych z obiegiem wody. Złożoność procesów i warunków glebowych wpływa na wykrywanie i kartowanie zagrożeń naturalnych, takich jak susze czy powodzie, w skalach globalnej lub regionalnej.
- Badanie pozostawia otwarte pytanie o utratę danych przestrzennych spowodowaną filtrowaniem danych GRACE o niskiej rozdzielczości czasowo - przestrzennej.

6.5 Publikacja [5]

Szabó, V., Osińska-Skotak, K. and Olszak, T. (2024) *'Using machine learning techniques to reconstruct the signal observed by the GRACE mission based on AMSR-E microwave data'*, *Miscellanea Geographica - Regional Studies on Development*, Vol. 28, No. 2 - 2024, doi: 10.2478/mgrsd-2023-0033

100 pkt MEiN; IF: 0.80

Publikacja [5] porusza problematykę synergetycznego wykorzystania teledetekcyjnych danych mikrofalowych oraz satelitarnych danych grawimetrycznych w celu modelowania zmian zachodzących w zasobach wód na podstawie danych z misji AMSR-E i GRACE. W badaniu przeanalizowano skuteczność różnych algorytmów uczenia maszynowego w modelowaniu wartości ΔTWS . Wyniki przedstawione w publikacji [4] zwracają uwagę na obszary zalesione i rolnicze, gdzie obserwacje GRACE i AMSR-E wykazują silną zgodność, podkreślając znaczenie dobrze natlenionych stref korzeniowych gleby. Przeprowadzone badanie identyfikuje ograniczenia związane z obecnością wiecznej zmarzliny na obszarach okołobiegunowych, która wpływa na wykorzystanie obserwacji mikrofalowych z pasma

X i C, rejestrowanych przez misję AMSR-E. Mimo ograniczonej korelacji w tych obszarach, modelowanie ΔTWS przy użyciu danych z AMSR-E okazuje się skuteczne, nawet w obszarach o dużej amplitudzie zmian, takich jak region Amazonii. Wyzwania związane z modelowaniem zmian hydrologicznych w obszarach rolniczych są również widoczne w wynikach przeprowadzonego eksperymentu badawczego, ze wskazaniem na wpływ czynników takich jak nawadnianie, przepuszczalność wody do głębszych warstw wodonośnych oraz zmienność okresów wegetacji. Eksperyment skupił się na przecięciu zbiorów danych sensorów GRACE i AMSR-E w okresie od 2002 do 2012 roku, strategicznie wybranym w celu maksymalizacji nakładania się zbiorów danych. Dane wejściowe do treningu modeli ML zostały starannie zorganizowane w formie tabelarycznej, gdzie każdy punkt danych odpowiadał macierzy reprezentującej różne epoki pomiarowe. Kolumny zawierały predyktory SM AMSR-E z pasm C i X, szerokości i długości geograficzne oraz zmienne dotyczące fal rocznych i półrocznych. Ta macierz odpowiada wektorowi zawierającemu ciągle zmienne ΔTWS , pełniącemu rolę zmiennej docelowej. Przed fazą treningu, odrębna część losowo wybranych danych powinna zostać wyznaczona w celu przetestowania dokładności i ewaluacji modelu. By uzyskać istotność statystyczną wyników modelu, ustalono minimalną liczbę próbek włączonych do zbioru testowego. Dane z lat 2002-2008 zostały uwzględnione w zbiorze treningowym, a dane z lat 2008-2012 zostały uwzględnione w zbiorze testowym. Wybór algorytmów regresji został podyktowany ich sprawdzoną skutecznością w obsłudze różnorodnych zbiorów danych i cech oraz ich przydatnością do modelowania badanego zjawiska. Korzystając z wcześniejszych badań, w których oceniono różne algorytmy uczenia maszynowego do zadań regresji, zidentyfikowano kilka popularnych metod ze względu na ich stabilne wyniki przy różnych charakterystykach danych. Wybór różnorodnych metod zapewnił wszechstronne eksplorowanie przestrzeni regresji i ułatwił solidne modelowanie badanego zjawiska, uwzględniając specyficzne cechy każdej z wybranych technik. Osiągnięte wyniki na próbie danych testowych przedstawiono w tabeli nr 1 publikacji [5]. Najlepsze wyniki osiągnięto za pomocą metod związanych z Lasami Losowymi, takimi jak Random Forest Regressor, Extra Trees Regressor oraz Extreme Gradient Boosting, uzyskując satysfakcjonujące wartości R^2 większe od 0.7, co pokazuje zgodność z ustalonymi standardami poprzez badaczy wskazywanymi w podobnych pracach naukowych. Rozkład przestrzenny błędów pokazano na rysunku nr 2 tej pracy. W kolejnym etapie przeprowadzono dyskusję możliwości łączenia pomiarów lokalnych zmian hydrologicznych w warstwach wodonośnych na podstawie synergii absolutnych pomiarów grawimetrycznych z pomiarami satelitarnymi. W publikacji [4] wskazano, że wielkość zlewni rzecznych nie wykazuje bezpośredniej korelacji z rozbieżnościami w sygnałach uzyskiwanych z GRACE i AMSR-E. Europejskie rzeki, takie jak Dunaj i Wisła, wykazują równoległe przesunięcia w sygnałach hydrologicznych, gdy obserwowane są za pomocą zarówno czuj-

ników grawimetrycznych, jak i mikrofalowych. Obserwacje z pasm X- i C wprowadzają bardziej wyraźną wariancję sygnału w porównaniu z obserwacjami GRACE. W rezultacie zidentyfikowane anomalie charakteryzują się podwyższonym poziomem szumu w tych zakresach częstotliwości. Podobnie jak w pracy [4], w przypadku pracy nr [5] przewidywanie fali powodziowej na podstawie danych SM z AMSR-E było nieudane. Metryki dla predykcji dla tego obszaru wykazują wartości, takie jak $NSE = -0.19$, $RMSE = 0.04$ [m], $NRMSE = 0.23$, $R^2 = 0.27$, i potwierdzają, że determinacja anomalii w tym obszarze widocznych w lokalnych pomiarach absolutnych w latach 2010-2011 jest zadaniem trudnym. Wymagałoby to prawdopodobnie danych ze znacznie dłuższego okresu obserwacji, w którym obserwowane byłyby także zjawiska powodzi o różnym nasileniu. Jednakże jak wskazano w pracach nr [1][2] odpowiednie opracowanie obserwacji grawimetrycznych wspomaga modelowanie ekstremalnych zjawisk klimatycznych, co w pracy nr [5] potwierdzono obserwując wyraźne korelacje między pomiarami absolutnymi a SM z AMSR-E w określonych okresach. Ujemna anomalia z grudnia 2009 roku była widoczna w obu seriach czasowych, co jest dowodem na wrażliwość sygnału grawimetrycznego na zmiany środowiskowe w głębszych warstwach wodonośnych.

Na podstawie przeprowadzonego badania wyszczególnić można następujące wnioski:

- Badanie wskazuje na wysoką skuteczność wykorzystania danych teledetekcyjnych AMSR-E do modelowania wartości ΔTWS na podstawie obserwacji z misji GRACE. Rezultaty te potwierdziły skuteczność i możliwość zastosowania technik uczenia maszynowego w analizie zmian zasobów wodnych.
- Obszary takie jak obszary wiecznej zmarzliny czy obszary intensywnej działalności rolniczej, mogą wprowadzać pewne wyzwania w dokładnym modelowaniu ΔTWS , ale mimo to istnieje potencjał do skutecznego zastosowania danych teledetekcyjnych do uzupełniania szeregów czasowych obserwacji grawimetrycznych.
- Określenie i przewidywanie anomalii dotyczących ekstremalnych zjawisk pogodowych widocznych w lokalnych pomiarach absolutnych w poszczególnych latach jest zadaniem trudnym, jednakże istnieją okresy dla których jest to możliwe. Dzięki synergicznemu wykorzystaniu obserwacji teledetekcyjnych i grawimetrycznych możliwe jest uzyskanie zadawalających rezultatów w kontekście modelowania zmian hydrologicznych.

7 Podsumowanie

W przedstawionej rozprawie doktorskiej podjęta została tematyka łączenia danych z sensorów mikrofalowych i grawimetrycznych dalekiego oraz bliskiego zasięgu. W cyklu pięciu publikacji omówiono poszczególne aspekty badawcze. Zbadano zależności tychże sensorów w kontekście obserwacji ekstremalnych zjawisk pogodowych. Oceniono wpływ metod filtracji danych GRACE poziomu 2 na możliwość uchwycenia minimalnej wielkości badanych zjawisk geofizycznych przez satelitarne sensory grawimetryczne. Przeprowadzona analiza szeregów czasowych wskazała, iż przy odpowiednim dobraniu sposobu filtracji możliwe jest uchwycenie zjawisk takich jak powodzie hydrologiczne charakteryzujące się wartością anomalii wykrywaną przez absolutne pomiary grawimetryczne na poziomie 3.5–14 μGal . Doprowadziło to bezpośrednio do ukierunkowania kolejnych badań w stronę analiz możliwości łączenia danych GRACE z pomiarami o innym spektrum czasowo-przestrzennym, w tym modeli hydrologicznych. **W badaniach posłużono się wybranymi uprzednio metodami statystycznymi w tym metodami wytłumaczalnej sztucznej inteligencji (XAI) wskazując na istotność czynników i parametrów fizycznych wpływających na rejestrację zmian poziomu wody w glebie spełniając tym samym wyznaczony cel badawczy.** Wykazana duża istotność cech fizycznych związanych z wilgotnością gleby oraz konieczność zastosowania spójnych i długich szeregów obserwacyjnych zadecydowała o wykorzystaniu w kolejnych badaniach danych dotyczących SM z misji AMSR-E. W pracy wykorzystano techniki rekonstrukcji sygnału używając poszczególnych sposobów modelowania regresji zjawiska ΔTWS . **W badaniach wskazano na istniejące obszary i uwarunkowania fizyczne tych przestrzeni, dla których jest możliwe dokładnie interpolowanie czasowo-przestrzenne danych GRACE na podstawie obserwacji z innych sensorów spełniając tym samym pierwszy cel badawczy i potwierdzając możliwość wzajemnej integracji danych teledetekcyjnych z grawimetrycznymi pod kątem uzyskania informacji i rozkładu wody w glebie.**

Na podstawie przeprowadzonych badań potwierdzono postawioną tezę wskazując, iż istnieją uwarunkowania, dla których występuje duża zgodność rejestracji zmian zawartości wód przypowierzchniowych obserwowanych za pomocą mikrofalowych technik teledetekcyjnych w zestawieniu ze zmianami całkowitego ekwiwalentu wodnego obserwowanymi przez satelitarne misje grawimetryczne. Przeprowadzony proces badawczy oraz relacje między publikacjami tworzącymi cykl przedstawiono na rysunku (6).

Na podstawie wyników badań zaprezentowanych w niniejszej rozprawie wyciągnięto następujące wnioski, które w opinii autora zasługują na wyszczególnienie:

- Sposób przetwarzania danych grawimetrycznych z misji GRACE i GRACE-FO jest niezwykle istotny w kontekście interpretacji prowadzonych analiz. Dokładności uzyskiwanych wyników zależą od przestrzenno-czasowych komponentów badanego sygnału geofizycznego, dlatego metodyka opracowania obserwacji jest kluczowa dla naukowców.
- Osiągnięcie zadowalających rezultatów przy analizie wychwytywania klimatycznych ekstremalnych wydarzeń takich jak susze i powódzie może z powodzeniem być wykonywane przy pomocy satelitarnych sensorów grawimetrycznych. Zastosowanie odpowiedniej filtracji przestrzennej sygnału jest znaczące dla wyników. Metody monitorowania zmian pola grawitacyjnego z pułapu satelitarnego okazały się skuteczne w identyfikacji ekstremalnych zdarzeń klimatologicznych na skalę regionalną ($< 100 km^2$). Analiza korelacji między różnymi danymi pomiarowymi in-situ potwierdziła ich zgodność na poziomie RMSE 4.5 - 5.2 μGal i korelacji krzyżowej 0.7-0.8, a przy uwzględnieniu korekty pomiarów związanej z czynnikami lokalnymi można stwierdzić znaczącą poprawę zbieżności tych sygnałów do wartości RMSE 4.1-5.2 μGal i korelacji krzyżowej 0.75-0.85.
- Modelowanie lokalnych czynników hydrologicznych, terenowych oraz antropogenicznych przy regionalnej analizie dokładnościowej grawimetrycznych obserwacji naziemnych i satelitarnych jest kluczowe w przypadku obserwacji ponadstandardowych warunków hydrologicznych. Usuwanie sezonowych komponentów z obserwacji umożliwia uwidocznienie anomalii związanych z sygnałem geofizycznym w postaci zwiększonej lub zmniejszonej zawartości wody w glebie.
- Nowoczesne techniki uczenia maszynowego mogą być z powodzeniem użyte w zadaniach związanych z rekonstrukcją sygnału ΔTWS obserwowanego przez misje GRACE i GRACE-FO na podstawie wielowymiarowych danych z modeli GLDAS. Kluczowe jest dobranie odpowiednich parametrów fizycznych modelu do tego zadania. W zależności od prowadzonych analiz regionalnych w podejściu czasowym lub globalnych w ujęciu czasowo-przestrzennym mogą istnieć różnice w istotności zastosowanych zmiennych, jednakże ogólna istotność grup zmiennych jest podobna i zachowana niezależnie od podejścia. Większej uwagi zdecydowanie wymagają obszary o silnych czynnikach antropogenicznych. W analizie dokładnościowej takie obszary charakteryzują się gorszymi metrykami. W zależności od warunków ukształtowania stref wodonośnych wartości spływu podpowierzchniowego i migracji wód są silną składową sygnału ΔTWS i nie powinny być pomijalne przy modelowaniu.

- Asymilacja danych grawimetrycznych i teledetekcyjnych, takich jak obserwacje Δ TWS i SM, ma kluczowe znaczenie dla lepszego zrozumienia procesów związanych z obiegiem wody na Ziemi. Synergia pomiarów Δ TWS i SM może zapewnić lepsze i wysokiej rozdzielczości zrozumienie procesów na Ziemi związanych z obiegiem wody. Złożoność procesów i warunków glebowych wpływa na wykrywanie i mapowanie zagrożeń naturalnych, takich jak susze czy powódzie, na skalę globalną lub regionalną. Zrozumienie ograniczeń wpływających na prędkość wykrywania zmian i spójności w obserwacjach za pomocą różnych metod i sensorów ma rzeczywisty wpływ na jakość rozwiązań stosowanych do przewidywania zagrożeń geofizycznych.
- Przeprowadzone badania wykazały, że obszary zalesione i duże przestrzenie rolnicze poprawiają zgodność między obserwacjami GRACE a AMSR-E charakteryzując się współczynnikiem korelacji pearsona na poziomie 0.8, podkreślając znaczenie parametru dotyczącego zawartości tlenu w strefach korzeniowych gleby. Ograniczenia glebowe, takie jak wieczna zmarzlina, eliminują użyteczność obserwacji mikrofalowych w zakresie X i C. Współczynnik NSE na poziomie -0.5 przy krekonstrukcji sygnału Δ TWS na tych obszarach oraz ujemna korelacja -0.5 - -0.25 wskazują na niską koherencję obserwacji mikrofalowych z grawimetrycznymi w tym obszarze. Badanie wykazało, że zrozumienie tych ograniczeń wpływa na jakość i spójność modelowanych wartości, co jest kluczowe dla predykcji geozagrożeń. Synergia między pomiarami Δ TWS i SM poprawia zrozumienie obiegu wody na Ziemi, ale istnieje pytanie o utratę danych przestrzennych związanych z filtrowaniem danych GRACE o niskiej rozdzielczości czasowo (miesięczne rozwiązania) - przestrzennej (300 x 300 km) w stosunku do pomiarów teledetekcyjnych (dane dobowe, średnia rozdzielczość przestrzenna 25 x 25 km).

Wyniki przeprowadzonych badań są istotnym elementem poszerzającym wiedzę w zakresie świadomości naukowców zajmujących się opracowywaniem danych grawimetrycznych rozwiązań miesięcznych modeli geopotencjału. Opracowywane dane znajdują swoich odbiorców w dziedzinach hydrologii, fizyki Ziemi, ale przede wszystkim w rolnictwie, klimatologii, gospodarce wodnej. Bez dobrego zrozumienia praw natury nie jest możliwe pełne korzystanie z jej darów w postaci niezwykle cennego surowca jakim jest woda. Badany temat jest jednym z wielu istotnych kręgów zainteresowań międzynarodowej społeczności naukowej i zgodny z celami GGOS.

8 Wykaz użytych skrótów i akronimów

ΔTWS (ang. Total Water Storage changes)

ACC (ang. Super STAR Accelorometers)

AMSR-2 (ang. Advanced Microwave Scanning Radiometer -2)

AMSR-3 (ang. Advanced Microwave Scanning Radiometer -3)

AMSR-E (ang. Advanced Microwave Scanning Radiometer -E)

ANN (ang. artificial neural networks)

ARIMA (ang. AutoRegressive Integrated Moving Average)

CC (Współczynnik korelacji Pearsona)

CDF (ang. Cumulative Distribution Function)

CES (ang. Coarse Earth and Sun Sensor)

CHAMP (ang. Challenging Minisatellite Payload)

CLM (ang. Community Land Model)

CMEM (ang. Community Microwave Emission Model)

CMTA (ang. Center of Mass Trim Assembly)

CNN (ang. convolutional neural network)

CSR (ang. Center for Sapce Research)

DLR (ger. Deutsches Zentrum für Luft-und Raumfahrt)

DNN (ang. deep neural network)

EMD (ang. Empirical Mode Decomposition)

EOF (ang. Empirical Orthogonal Functions)

EOS (ang. Earth Observing System)

ESA (ang. European Space Agency)

GEOSS (ang. Global Earth Observation System of Systems)

GFZ (ger. GeoForschungsZentrum)

GGOS (ang. Global Geodetic Observing System)

GHRC DAAC (ang. Global Hydrometeorology Resource Center Distributed Active Archive Center)

GIA (ang. Glacial isostatic adjustment)

GLDAS (ang. Global Land Data Assimilation System)

GOCE (ang. Gravity field and steady-state Ocean Circulation Explorer)

GOSAT-GW (ang. Global Observing SATellite for Greenhouse gases and Water cycle)

GPS (ang. Global Positioning System)

GRACE (ang. Gravity Recovery And Climate Experiment)

GRACE-FO (ang. Grace Follow on)

GSA (ang. Globalstar Silicon Solar Cell Arrays)

GWS (ang. groundwater storage variations)

HL (ang. high–low)

IERS2010 (ang. International Earth Rotation and Reference Systems Service Convention)

ITGRF (ang. International Terrestrial Gravity Reference Frame)

ITRF (ang. International Terrestrial Reference Frame)

ITRS (ang. International Terrestrial Reference System)

JAXA (ang. Japan Aerospace Exploration Agency)

JOZE (obserwatorium Astronomiczno-Geodezyjnym w Józefosławiu Politechniki Warszawskiej)

JPL (ang. Jet Propulsion Laboratory)

KBR (ang. K-band Ranging System)

KS (Test Kolmogorova-Smirnova)

L-MEB (ang. Land Microwave Emission Model for Brightness Temperature)

LAGEOS (ang. Laser Geodynamics Satellite)

LARS (ang. Least Angle Regression)

LightGBM (ang. Light Gradient Boosting Machine)

LL-SST (ang. low-low satellite-to-satellite tracking)

LPRM (ang. Land Parameter Retrieval Model)

LRI (ang. Laser Range Interferometry)

LSSA (ang. Least-Squares Spectral Analysis)

MCA (ang. Maximum Covariance Analysis)

ML (ang. machine learning)

MODIS (ang. Moderate Resolution Imaging Spectroradiometer)

NASA (ang. National Aeronautics and Space Administration)

NRMSE (ang. Normalized Root Mean Square Error)

NSE (ang. Nash-Sutcliffe Efficiency)

NSIDC (ang. National Snow and Ice Data Center)

PCA (ang. Principal Component Analysis)

RFI (ang. radio frequency interference)

RMSE (ang. Root Mean Square Error)

RNN (ang. Recurrent Neural Network)

SARIMAX (ang. seasonal autoregressive integrated moving average model)

SCA (ang. Soil Canopy Atmosphere)

SCA (ang. Star Camera Assembly)

SEATS (ang. Seasonal Extraction in ARIMA Time Series)

SHAP (ang. SHapley Additive exPlanations)

SIPS-RSS (ang. Science Investigator-led Processing Systems - Remote Sensing System)

SLR (ang. satellite laser ranging)

SM (ang. Soil Moisture)

SMC (ang. Soil Moisture Content)

STL (ang. seasonal trend decomposition)

SVM (ang. Support Vector Machines)

TSA (ang. temporal stability analysis)

TWSA (ang. Total Water Storage anomaly)

USA (ang. United States of America)

USO (ang. Ultra Stable Oscillator)

UTCSR (ang. University of Texas at Austin - Center for Space Research)

VIC (ang. Variable Infiltration Capacity)

XAI (ang. explainable artificial intelligence)

XGBoost (ang. Extreme gradient boosting)

9 Bibliografia

- Abe, M., Kroner, C., Förste, C., Petrovic, S., Barthelmes, F., Weise, A., Güntner, A., Creutzfeldt, B., Jahr, T., Jentzsch, G., et al. (2012). A comparison of grace-derived temporal gravity variations with observations of six european superconducting gravimeters. *Geophysical Journal International*, 191(2):545–556.
- Abelen, S., Seitz, F., Abarca-del Rio, R., and Güntner, A. (2015). Droughts and floods in the la plata basin in soil moisture data and grace. *Remote Sensing*, 7(6):7324–7349.
- Abelen, S., Seitz, F., Schmidt, M., and Güntner, A. (2011). Analysis of regional variations in soil moisture by means of remote sensing, satellite gravimetry and hydrological modelling. *GRACE, Remote Sensing and Ground-Based Methods in Multi-Scale Hydrology, IAHS Red Book Series*, (343):9–15.
- Ahmed, M., Sultan, M., Elbayoumi, T., and Tissot, P. (2019). Forecasting grace data over the african watersheds using artificial neural networks. *Remote Sensing*, 11(15):1769.
- Andersen, O. B., Seneviratne, S. I., Hinderer, J., and Viterbo, P. (2005). Grace-derived terrestrial water storage depletion associated with the 2003 european heat wave. *Geophysical Research Letters*, 32(18).
- Angrist, J. D. (2001). Estimation of limited dependent variable models with dummy endogenous regressors: simple strategies for empirical practice. *Journal of business & economic statistics*, 19(1):2–28.
- Arrieta, A. B., Díaz-Rodríguez, N., Del Ser, J., Bennetot, A., Tabik, S., Barbado, A., García, S., Gil-López, S., Molina, D., Benjamins, R., et al. (2020). Explainable artificial intelligence (xai): Concepts, taxonomies, opportunities and challenges toward responsible ai. *Information fusion*, 58:82–115.
- Babaeian, E., Sadeghi, M., Jones, S. B., Montzka, C., Vereecken, H., and Tuller, M. (2019). Ground, proximal, and satellite remote sensing of soil moisture. *Reviews of Geophysics*, 57(2):530–616.
- Balenzano, A., Mattia, F., Satalino, G., Lovergine, F. P., Palmisano, D., Peng, J., Marzahn, P., Wegmüller, U., Cartus, O., Dąbrowska-Zielińska, K., et al. (2021). Sentinel-1 soil moisture at 1 km resolution: a validation study. *Remote Sensing of Environment*, 263:112554.
- Bartalis, Z., Wagner, W., Naeimi, V., Hasenauer, S., Scipal, K., Bonekamp, H., Figa, J., and Anderson, C. (2007). Initial soil moisture retrievals from the metop-a advanced scatterometer (ascat). *Geophysical Research Letters*, 34(20).
- Becker, M., Meyssignac, B., Xavier, L., Cazenave, A., Alkama, R., and Decharme, B.

- (2011). Past terrestrial water storage (1980–2008) in the amazon basin reconstructed from grace and in situ river gauging data. *Hydrology and Earth System Sciences*, 15(2):533–546.
- Bettadpur, S. (2007). Level-2 gravity field product user handbook. *The GRACE Project (Jet Propulsion Laboratory, Pasadena, CA, 2003)*.
- Betts, A. K., Ball, J. H., Beljaars, A., Miller, M., and Viterbo, P. (1994). Coupling between land-surface boundary-layer parameterizations and rainfall on local and regional scales: Lessons from the wet summer of 1993. In *Fifth Symp. on Global Change Studies*, pages 174–181.
- Bhanja, S. N., Mukherjee, A., Saha, D., Velicogna, I., and Famiglietti, J. S. (2016). Validation of grace based groundwater storage anomaly using in-situ groundwater level measurements in india. *Journal of Hydrology*, 543:729–738.
- Birylo, M. and Rzepecka, Z. (2023). Remote sensing-based hydro-extremes assessment techniques for small area case study (the case study of poland). *Remote Sensing*, 15(21):5226.
- Birylo, M., Rzepecka, Z., and Nastula, J. (2018). Assessment of the water budget from gldas model. In *2018 Baltic Geodetic Congress (BGC Geomatics)*, pages 86–90. IEEE.
- Bonaccorso, G. (2018). *Machine Learning Algorithms: Popular algorithms for data science and machine learning*. Packt Publishing Ltd.
- Böning, C., Timmermann, R., Macrandar, A., and Schröter, J. (2008). A pattern-filtering method for the determination of ocean bottom pressure anomalies from grace solutions. *Geophysical Research Letters*, 35(18).
- Box, G. E. and Pierce, D. A. (1970). Distribution of residual autocorrelations in autoregressive-integrated moving average time series models. *Journal of the American statistical Association*, 65(332):1509–1526.
- Breiman, L. (2001). Random forests. *Machine learning*, 45:5–32.
- Chai, T. and Draxler, R. R. (2014). Root mean square error (rmse) or mean absolute error (mae)?—arguments against avoiding rmse in the literature. *Geoscientific model development*, 7(3):1247–1250.
- Chao, N., Wang, Z., Jiang, W., and Chao, D. (2016). A quantitative approach for hydrological drought characterization in southwestern china using grace. *Hydrogeology Journal*, 24(4):893–903.
- Chen, F., Crow, W. T., Bindlish, R., Colliander, A., Burgin, M. S., Asanuma, J., and Aida, K. (2018). Global-scale evaluation of smap, smos and ascat soil moisture products using triple collocation. *Remote Sensing of Environment*, 214:1–13.

- Chen, J., Wilson, C., and Ries, J. (2016). Broadband assessment of degree-2 gravitational changes from grace and other estimates, 2002–2015. *Journal of Geophysical Research: Solid Earth*, 121(3):2112–2128.
- Chen, J., Wilson, C., and Seo, K.-W. (2006). Optimized smoothing of gravity recovery and climate experiment (grace) time-variable gravity observations. *Journal of Geophysical Research: Solid Earth*, 111(B6).
- Chen, J. L., Wilson, C. R., and Tapley, B. D. (2010). The 2009 exceptional amazon flood and interannual terrestrial water storage change observed by grace. *Water Resources Research*, 46(12).
- Chen, J. L., Wilson, C. R., Tapley, B. D., and Grand, S. (2007). Grace detects coseismic and postseismic deformation from the sumatra-andaman earthquake. *Geophysical Research Letters*, 34(13).
- Chen, T. and Guestrin, C. (2016). Xgboost: A scalable tree boosting system. In *Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining*, pages 785–794.
- Chen, X.-z., Chen, S.-s., Zhong, R.-f., Su, Y.-x., Liao, J.-s., Li, D., Han, L.-s., Li, Y., and Li, X. (2012). A semi-empirical inversion model for assessing surface soil moisture using amsr-e brightness temperatures. *Journal of hydrology*, 456:1–11.
- Chen, Y., Yang, K., Qin, J., Zhao, L., Tang, W., and Han, M. (2013). Evaluation of amsr-e retrievals and gldas simulations against observations of a soil moisture network on the central tibetan plateau. *Journal of Geophysical Research: Atmospheres*, 118(10):4466–4475.
- Cheng, M. and Tapley, B. D. (2004). Variations in the earth’s oblateness during the past 28 years. *Journal of Geophysical Research: Solid Earth*, 109(B9).
- Cheng, M., Tapley, B. D., and Ries, J. C. (2013). Deceleration in the earth’s oblateness. *Journal of Geophysical Research: Solid Earth*, 118(2):740–747.
- Cleveland, R. B., Cleveland, W. S., McRae, J. E., and Terpenning, I. (1990). Stl: A seasonal-trend decomposition. *J. Off. Stat*, 6(1):3–73.
- Cleveland, W. P. and Tiao, G. C. (1976). Decomposition of seasonal time series: a model for the census x-11 program. *Journal of the American statistical Association*, 71(355):581–587.
- Cohen, I., Huang, Y., Chen, J., Benesty, J., Benesty, J., Chen, J., Huang, Y., and Cohen, I. (2009). Pearson correlation coefficient. *Noise reduction in speech processing*, pages 1–4.
- Cooley, S.S.; Landerer, F. (2021). Grace d-103133 gravity recovery and climate experiment

follow-on (grace-fo). *Level-3 Data Product User Handbook*.

Cover, T. and Hart, P. (1967). Nearest neighbor pattern classification. *IEEE transactions on information theory*, 13(1):21–27.

Cox, C. M. and Chao, B. F. (2002). Detection of a large-scale mass redistribution in the terrestrial system since 1998. *Science*, 297(5582):831–833.

Crossley, D., de Linage, C., Hinderer, J., Boy, J.-P., and Famiglietti, J. (2012). A comparison of the gravity field over central europe from superconducting gravimeters, grace and global hydrological models, using eof analysis. *Geophysical Journal International*, 189(2):877–897.

Crow, W. T., Berg, A. A., Cosh, M. H., Loew, A., Mohanty, B. P., Panciera, R., de Rosnay, P., Ryu, D., and Walker, J. P. (2012). Upscaling sparse ground-based soil moisture observations for the validation of coarse-resolution satellite soil moisture products. *Reviews of Geophysics*, 50(2).

Crow, W. T., Lei, F., Hain, C., Anderson, M. C., Scott, R. L., Billesbach, D., and Arkebauer, T. (2015). Robust estimates of soil moisture and latent heat flux coupling strength obtained from triple collocation. *Geophysical Research Letters*, 42(20):8415–8423.

Dahle, C., Flechtner, F., Gruber, C., König, D., König, R., Michalak, G., and Neumayer, K.-H. (2013). Gfz grace level-2 processing standards document for level-2 product release 0005: revised edition, january 2013.

Dahle, C., Flechtner, F., Gruber, C., König, D., König, R., Michalak, G., and Neumayer, K.-H. (2014). Gfz rl05: an improved time-series of monthly grace gravity field solutions. In *Observation of the System Earth from Space-CHAMP, GRACE, GOCE and future missions*, pages 29–39. Springer.

Dahle, C., Murböck, M., Flechtner, F., Dobsław, H., Michalak, G., Neumayer, K. H., Abrykosov, O., Reinhold, A., König, R., Sulzbach, R., et al. (2019). The gfz grace rl06 monthly gravity field time series: Processing details and quality assessment. *Remote Sensing*, 11(18):2116.

De Jeu, R. A., Wagner, W., Holmes, T., Dolman, A., Van De Giesen, N., and Friesen, J. (2008). Global soil moisture patterns observed by space borne microwave radiometers and scatterometers. *Surveys in Geophysics*, 29(4):399–420.

De Villiers, M. (2001). *Water: The fate of our most precious resource*. Houghton Mifflin Harcourt.

Dee, D. P., Uppala, S. M., Simmons, A. J., Berrisford, P., Poli, P., Kobayashi, S., Andrae, U., Balmaseda, M., Balsamo, G., Bauer, d. P., et al. (2011). The era-interim reanalysis:

Configuration and performance of the data assimilation system. *Quarterly Journal of the royal meteorological society*, 137(656):553–597.

Doan, T. and Kalita, J. (2015). Selecting machine learning algorithms using regression models. In *2015 IEEE International Conference on Data Mining Workshop (ICDMW)*, pages 1498–1505. IEEE.

Döll, P., Müller Schmied, H., Schuh, C., Portmann, F. T., and Eicker, A. (2014). Global-scale assessment of groundwater depletion and related groundwater abstractions: Combining hydrological modeling with information from well observations and grace satellites. *Water Resources Research*, 50(7):5698–5720.

Draper, C. S., Walker, J. P., Steinle, P. J., De Jeu, R. A., and Holmes, T. R. (2009). An evaluation of amsr-e derived soil moisture over australia. *Remote Sensing of Environment*, 113(4):703–710.

Drusch, M., Scipal, K., De Rosnay, P., Balsamo, G., Andersson, E., Bougeault, P., and Viterbo, P. (2009). Towards a kalman filter based soil moisture analysis system for the operational ecmwf integrated forecast system. *Geophysical Research Letters*, 36(10).

Du, J., Kimball, J., Velicogna, I., Zhao, M., Jones, L., Watts, J., and Kim, Y. (2019). Multicomponent satellite assessment of drought severity in the contiguous united states from 2002 to 2017 using amsr-e and amsr2. *Water Resources Research*, 55(7):5394–5412.

Dutt Vishwakarma, B., Devaraju, B., and Sneeuw, N. (2016). Minimizing the effects of filtering on catchment scale grace solutions. *Water Resources Research*, 52(8):5868–5890.

Efron, B., Hastie, T., Johnstone, I., and Tibshirani, R. (2004). Least angle regression.

Eicker, A., Schumacher, M., Kusche, J., Döll, P., and Schmied, H. M. (2014). Calibration/data assimilation approach for integrating grace data into the watgap global hydrology model (wghm) using an ensemble kalman filter: First results. *Surveys in Geophysics*, 35(6):1285–1309.

Elith, J., Leathwick, J. R., and Hastie, T. (2008). A working guide to boosted regression trees. *Journal of animal ecology*, 77(4):802–813.

Engman, E. T. (1992). Soil moisture needs in earth sciences. In *In: IGARSS’92; Proceedings of the 12th Annual International Geoscience and Remote Sensing Symposium, Houston, TX, May 26-29, 1992. Vol. 1 (A93-47551 20-43)*. Institute of Electrical and Electronics Engineers, Inc.

Entekhabi, D., Nakamura, J., and Njoku, E. (1994). Retrieval of soil moisture profile by combined remote sensing and modeling. *Passive Microwave Remote Sensing of Land-Atmosphere Interactions: [ESA/NASA International Workshop, Held at Saint Lary*

(France) from January 11–15, 1993].

Eom, J., Seo, K.-W., and Ryu, D. (2017). Estimation of amazon river discharge based on eof analysis of grace gravity data. *Remote Sensing of Environment*, 191:55–66.

Famiglietti, J. S., Ryu, D., Berg, A. A., Rodell, M., and Jackson, T. J. (2008). Field observations of soil moisture variability across scales. *Water Resources Research*, 44(1).

Fast, J. D. and McCorcle, M. D. (1991). The effect of heterogeneous soil moisture on a summer baroclinic circulation in the central united states. *Monthly weather review*, 119(9):2140–2167.

Feng, W., Zhong, M., Lemoine, J.-M., Biancale, R., Hsu, H.-T., and Xia, J. (2013). Evaluation of groundwater depletion in north china using the gravity recovery and climate experiment (grace) data and ground-based measurements. *Water Resources Research*, 49(4):2110–2118.

Fisher, A., Rudin, C., and Dominici, F. (2019). All models are wrong, but many are useful: Learning a variable’s importance by studying an entire class of prediction models simultaneously. *J. Mach. Learn. Res.*, 20(177):1–81.

Flechtner, F., Neumayer, K.-H., Dahle, C., Dobsław, H., Fagiolini, E., Raimondo, J.-C., and Güntner, A. (2016). What can be expected from the grace-fo laser ranging interferometer for earth science applications? In *Remote sensing and water resources*, pages 263–280. Springer.

Forootan, E., Rietbroek, R., Kusche, J., Sharifi, M. A., Awange, J. L., Schmidt, M., Omondi, P., and Famiglietti, J. (2014). Separation of large scale water storage patterns over iran using grace, altimetry and hydrological data. *Remote Sensing of Environment*, 140:580–595.

Foroumandi, E., Nourani, V., Huang, J. J., and Moradkhani, H. (2023). Drought monitoring by downscaling grace-derived terrestrial water storage anomalies: A deep learning approach. *Journal of Hydrology*, 616:128838.

Friedman, J. H. (2001). Greedy function approximation: a gradient boosting machine. *Annals of statistics*, pages 1189–1232.

Friedman, J. H. (2002). Stochastic gradient boosting. *Computational statistics & data analysis*, 38(4):367–378.

Fu, T.-c. (2011). A review on time series data mining. *Engineering Applications of Artificial Intelligence*, 24(1):164–181.

GCOM-MAS-100045A (2013). Aqua amsr-e level 1 product format description document. *Global Change Observation Mission Water*.

- GCOM-SGC-120011 (2013). Gcom-w1 "shizuku" data users handbook. *Global Change Observation Mission Water*.
- Geurts, P., Ernst, D., and Wehenkel, L. (2006). Extremely randomized trees. *Machine learning*, 63:3–42.
- Godah, W., Szelachowska, M., and Krynski, J. (2015). On the selection of grace-based ggms and a filtering method for estimating mass variations in the earth system over poland. *Geoinf. Issues*, 7(1):5–14.
- Godah, W., Szelachowska, M., and Krynski, J. (2017). On the analysis of temporal geoid height variations obtained from grace-based ggms over the area of poland. *Acta geophysica*, 65:713–725.
- Godah, W., Szelachowska, M., Ray, J. D., and Krynski, J. (2020). Comparison of vertical deformations of the earth’s surface obtained using grace-based ggms and gnss data—a case study of south-eastern poland. *Acta geodynamica et geomaterialia*, 17(2).
- Gouweleeuw, B. T., Kvas, A., Grüber, C., Gain, A. K., Mayer-Gürr, T., Flechtner, F., and Güntner, A. (2017). Daily grace gravity field solutions track major flood events in the ganges-brahmaputra delta. *Hydrology and Earth System Sciences Discussions*, 22:1–23.
- Grömping, U. (2009). Variable importance assessment in regression: linear regression versus random forest. *The American Statistician*, 63(4):308–319.
- Gruber, A., Dorigo, W. A., Crow, W., and Wagner, W. (2017). Triple collocation-based merging of satellite soil moisture retrievals. *IEEE Transactions on Geoscience and Remote Sensing*, 55(12):6780–6792.
- Haining, R. P., Kerry, R., and Oliver, M. A. (2010). Geography, spatial data analysis, and geostatistics: An overview. *Geographical Analysis*, 42(1):7–31.
- Hamshaw, S. D., Dewoolkar, M. M., Schroth, A. W., Wemple, B. C., and Rizzo, D. M. (2018). A new machine-learning approach for classifying hysteresis in suspended-sediment discharge relationships using high-frequency monitoring data. *Water Resources Research*, 54(6):4040–4058.
- Hans, C. (2009). Bayesian lasso regression. *Biometrika*, 96(4):835–845.
- Hao, Z., Singh, V. P., and Xia, Y. (2018). Seasonal drought prediction: Advances, challenges, and future prospects. *Reviews of Geophysics*, 56(1):108–141.
- Hasan, E. and Tarhule, A. (2021). Comparison of decadal water storage trends from common grace releases (rl05, rl06) using spatial diagnostics and a modified triple collocation approach. *Journal of Hydrology X*, 13:100108.
- He, R., Zhang, L., and Chew, A. W. Z. (2022). Modeling and predicting rainfall time series

using seasonal-trend decomposition and machine learning. *Knowledge-Based Systems*, 251:109125.

Hodges Jr, J. (1958). The significance probability of the smirnov two-sample test. *Arkiv för matematik*, 3(5):469–486.

Horvath, A., Murböck, M., Pail, R., and Horwath, M. (2018). Decorrelation of grace time variable gravity field solutions using full covariance information. *Geosciences*, 8(9):323.

Ioannidis, J. P. (2005). Why most published research findings are false. *PLoS medicine*, 2(8):e124.

Irrgang, C., Saynisch-Wagner, J., Dill, R., Boergens, E., and Thomas, M. (2020). Self-validating deep learning for recovering terrestrial water storage from gravity and altimetry measurements. *Geophysical Research Letters*, 47(17):e2020GL089258.

Jackson, T., Hawley, M., and O’neill, P. (1987). Preplanting soil moisture using passive microwave sensors 1. *JAWRA Journal of the American Water Resources Association*, 23(1):11–19.

Jackson, T., Schugge, T., Nicks, A., Coleman, G., and Engman, E. (1981). Soil moisture updating and microwave remote sensing for hydrological simulation/la remise à jour de l’état d’humidité des sols en vue de la simulation hydrologique. *Hydrological Sciences Journal*, 26(3):305–319.

Jackson, T. J., Cosh, M. H., Bindlish, R., Starks, P. J., Bosch, D. D., Seyfried, M., Goodrich, D. C., Moran, M. S., and Du, J. (2010). Validation of advanced microwave scanning radiometer soil moisture products. *IEEE Transactions on Geoscience and Remote Sensing*, 48(12):4256–4272.

Jain, K., Sneeuw, N., Devaraju, B., et al. (2013). Mumbai 2005, bihar 2008 flood reflected in mass changes seen by grace satellites. *Journal of the Indian Society of Remote Sensing*, 41(3):687–695.

Jing, W., Di, L., Zhao, X., Yao, L., Xia, X., Liu, Y., Yang, J., Li, Y., and Zhou, C. (2020). A data-driven approach to generate past grace-like terrestrial water storage solution by calibrating the land surface model simulations. *Advances in Water Resources*, 143:103683.

Joodaki, G., Wahr, J., and Swenson, S. (2014). Estimating the human contribution to groundwater depletion in the middle east, from grace data, land surface models, and well observations. *Water Resources Research*, 50(3):2679–2692.

Kasahara, M., Kachi, M., Inaoka, K., Fujii, H., Kubota, T., Shimada, R., and Kojima, Y. (2020). Overview and current status of gosat-gw mission and amsr3 instrument. In *Sensors, Systems, and Next-Generation Satellites XXIV*, volume 11530, page 1153007.

SPIE.

Kattenborn, T., Leitloff, J., Schiefer, F., and Hinz, S. (2021). Review on convolutional neural networks (cnn) in vegetation remote sensing. *ISPRS journal of photogrammetry and remote sensing*, 173:24–49.

Kawanishi, T., Sezai, T., Ito, Y., Imaoka, K., Takeshima, T., Ishido, Y., Shibata, A., Miura, M., Inahata, H., and Spencer, R. W. (2003). The advanced microwave scanning radiometer for the earth observing system (amsr-e), nasda’s contribution to the eos for global energy and water cycle studies. *IEEE Transactions on Geoscience and Remote Sensing*, 41(2):184–194.

Ke, G., Meng, Q., Finley, T., Wang, T., Chen, W., Ma, W., Ye, Q., and Liu, T.-Y. (2017). Lightgbm: A highly efficient gradient boosting decision tree. *Advances in neural information processing systems*, 30.

Kermarrec, G., Klos, A., Lenczuk, A., and Bogusz, J. (2023). Long-term temporal-scales of hydrosphere changes observed by gps over europe: a comparison with grace and enso. *IEEE Geoscience and Remote Sensing Letters*.

Kerr, Y. H., Al-Yaari, A., Rodriguez-Fernandez, N., Parrens, M., Molero, B., Leroux, D., Bircher, S., Mahmoodi, A., Mialon, A., Richaume, P., et al. (2016). Overview of smos performance in terms of global soil moisture monitoring after six years in operation. *Remote Sensing of Environment*, 180:40–63.

Khaki, M., Schumacher, M., Forootan, E., Kuhn, M., Awange, J. L., and van Dijk, A. I. (2017). Accounting for spatial correlation errors in the assimilation of grace into hydrological models through localization. *Advances in Water Resources*, 108:99–112.

Klees, R., Liu, X., Wittwer, T., Gunter, B., Revtova, E., Tenzer, R., Ditmar, P., Winsemius, H., and Savenije, H. (2008). A comparison of global and regional grace models for land hydrology. *Surveys in Geophysics*, 29(4):335–359.

Koike, T., Nakamura, Y., Kaihotsu, I., Davaa, G., Matsuura, N., Tamagawa, K., and Fujii, H. (2004). Development of an advanced microwave scanning radiometer (amsr-e) algorithm for soil moisture and vegetation water content. *Proceedings of Hydraulic Engineering*, 48:217–222.

Kusche, J. (2007). Approximate decorrelation and non-isotropic smoothing of time-variable grace-type gravity field models. *Journal of Geodesy*, 81(11):733–749.

Kusche, J., Eicker, A., Forootan, E., Springer, A., and Longuevergne, L. (2016). Mapping probabilities of extreme continental water storage changes from space gravimetry. *Geophysical Research Letters*, 43(15):8026–8034.

- Kusche, J., Schmidt, R., Petrovic, S., and Rietbroek, R. (2009). Decorrelated grace time-variable gravity solutions by gfg, and their validation using a hydrological model. *Journal of geodesy*, 83(10):903–913.
- Landerer, F. W. and Swenson, S. (2012). Accuracy of scaled grace terrestrial water storage estimates. *Water resources research*, 48(4).
- Landerer, F. W., Wiese, D. N., Bentel, K., Boening, C., and Watkins, M. M. (2015). North atlantic meridional overturning circulation variations from grace ocean bottom pressure anomalies. *Geophysical Research Letters*, 42(19):8114–8121.
- Lautenbacher, C. C. (2006). The global earth observation system of systems: Science serving society. *Space Policy*, 22(1):8–11.
- Lei, J., Matsuo, T., Dou, X., Sutton, E., and Luan, X. (2012). Annual and semiannual variations of thermospheric density: Eof analysis of champ and grace data. *Journal of Geophysical Research: Space Physics*, 117(A1).
- Lenczuk, A., Klos, A., and Bogusz, J. (2023). Studying spatio-temporal patterns of vertical displacements caused by groundwater mass changes observed with gps. *Remote Sensing of Environment*, 292:113597.
- Lenczuk, A., Leszczuk, G., Klos, A., Kosek, W., and Bogusz, J. (2020). Study on the inter-annual hydrology-induced deformations in europe using grace and hydrological models. *Journal of Applied Geodesy*, 14(4):393–403.
- Li, Q. and Lin, N. (2010). The bayesian elastic net.
- Liu, X., Feng, X., Ciais, P., Fu, B., Hu, B., and Sun, Z. (2020). Grace satellite-based drought index indicating increased impact of drought over major basins in china during 2002–2017. *Agricultural and Forest Meteorology*, 291:108057.
- Liu, Y., Dorigo, W. A., Parinussa, R., de Jeu, R. A., Wagner, W., McCabe, M. F., Evans, J., and Van Dijk, A. (2012). Trend-preserving blending of passive and active microwave soil moisture retrievals. *Remote Sensing of Environment*, 123:280–297.
- Liu, Y. Y., Parinussa, R., Dorigo, W. A., De Jeu, R. A., Wagner, W., Van Dijk, A., McCabe, M. F., and Evans, J. (2011). Developing an improved soil moisture dataset by blending passive and active microwave satellite-based retrievals. *Hydrology and Earth System Sciences*, 15(2):425–436.
- Long, D., Shen, Y., Sun, A., Hong, Y., Longuevergne, L., Yang, Y., Li, B., and Chen, L. (2014). Drought and flood monitoring for a large karst plateau in southwest china using extended grace data. *Remote Sensing of Environment*, 155:145–160.
- Longuevergne, L., Scanlon, B. R., and Wilson, C. R. (2010). Grace hydrological estimates

- for small basins: Evaluating processing approaches on the high plains aquifer, usa. *Water Resources Research*, 46(11).
- Lundberg, S. M. and Lee, S.-I. (2017). A unified approach to interpreting model predictions. *Advances in neural information processing systems*, 30.
- Luzum, B. and Petit, G. (2012). The iers conventions (2010): reference systems and new models. *Proceedings of the International Astronomical Union*, 10(H16):227–228.
- Lvovich, M. I. (1979). *World water resources and their future*. American Geophysical Union.
- Macrander, A., Böning, C., Boebel, O., and Schröter, J. (2010). Validation of grace gravity fields by in-situ data of ocean bottom pressure. *System Earth via geodetic-geophysical space techniques*, pages 169–185.
- Martínez-Fernández, J. and Ceballos, A. (2005). Mean soil moisture estimation using temporal stability analysis. *Journal of Hydrology*, 312(1-4):28–38.
- Maulud, D. and Abdulazeez, A. M. (2020). A review on linear regression comprehensive in machine learning. *Journal of Applied Science and Technology Trends*, 1(4):140–147.
- McDonald, G. C. (2009). Ridge regression. *Wiley Interdisciplinary Reviews: Computational Statistics*, 1(1):93–100.
- Miro, M. E. and Famiglietti, J. S. (2018). Downscaling grace remote sensing datasets to high-resolution groundwater storage change maps of california’s central valley. *Remote Sensing*, 10(1):143.
- Mladenova, I., Jackson, T., Njoku, E., Bindlish, R., Chan, S., Cosh, M., Holmes, T., De Jeu, R., Jones, L., Kimball, J., et al. (2014). Remote monitoring of soil moisture using passive microwave-based techniques—theoretical basis and overview of selected algorithms for amsr-e. *Remote sensing of environment*, 144:197–213.
- Mo, S., Zhong, Y., Shi, X., Feng, W., Yin, X., and Wu, J. (2021). Improving prediction of the terrestrial water storage anomalies during the grace and grace-fo gap with bayesian convolutional neural networks. *arXiv preprint arXiv:2101.09361*.
- Mo, T., Choudhury, B., Schmugge, T., Wang, J. R., and Jackson, T. (1982). A model for microwave emission from vegetation-covered fields. *Journal of Geophysical Research: Oceans*, 87(C13):11229–11237.
- Nagelkerke, N. J. et al. (1991). A note on a general definition of the coefficient of determination. *biometrika*, 78(3):691–692.
- Nash, J. (1970). River flow forecasting through conceptual models, i: A discussion of principles. *Journal of Hydrology*, 10:398–409.

- Nastula, J. and Śliwińska, J. (2020). Prograde and retrograde terms of gravimetric polar motion excitation estimates from the grace monthly gravity field models. *Remote Sensing*, 12(1):138.
- Nastula, J., Śliwińska, J., Kur, T., Wińska, M., and Partyka, A. (2022). Preliminary study on hydrological angular momentum determined from cmip6 historical simulations. *Earth, Planets and Space*, 74(1):84.
- Navarra, A. and Simoncini, V. (2010). *A guide to empirical orthogonal functions for climate data analysis*. Springer Science & Business Media.
- Neumeyer, J., Barthelmes, F., Kroner, C., Petrovic, S., Schmidt, R., Virtanen, H., and Wilmes, H. (2008). Analysis of gravity field variations derived from superconducting gravimeter recordings, the grace satellite and hydrological models at selected european sites. *Earth, planets and space*, 60(5):505–518.
- Njoku, E. G., Ashcroft, P., Chan, T. K., and Li, L. (2005). Global survey and statistics of radio-frequency interference in amsr-e land observations. *IEEE Transactions on Geoscience and Remote Sensing*, 43(5):938–947.
- Njoku, E. G. and Entekhabi, D. (1996). Passive microwave remote sensing of soil moisture. *Journal of hydrology*, 184(1-2):101–129.
- Njoku, E. G., Jackson, T. J., Lakshmi, V., Chan, T. K., and Nghiem, S. V. (2003). Soil moisture retrieval from amsr-e. *IEEE transactions on Geoscience and remote sensing*, 41(2):215–229.
- Owe, M., de Jeu, R., and Walker, J. (2001). A methodology for surface soil moisture and vegetation optical depth retrieval using the microwave polarization difference index. *IEEE Transactions on Geoscience and Remote Sensing*, 39(8):1643–1654.
- Pail, R., Bingham, R., Braitenberg, C., Dobsław, H., Eicker, A., Güntner, A., Horwath, M., Ivins, E., Longuevergne, L., Panet, I., et al. (2015). Science and user needs for observing global mass transport to understand global change and to benefit society. *Surveys in Geophysics*, 36(6):743–772.
- Peltier, W., Argus, D. F., and Drummond, R. (2018). Comment on “an assessment of the ice-6g_c (vm5a) glacial isostatic adjustment model” by purcell et al. *Journal of Geophysical Research: Solid Earth*, 123(2):2019–2028.
- Peng, J., Albergel, C., Balenzano, A., Brocca, L., Cartus, O., Cosh, M. H., Crow, W. T., Dabrowska-Zielinska, K., Dadson, S., Davidson, M. W., et al. (2021). A roadmap for high-resolution satellite soil moisture applications—confronting product characteristics with user requirements. *Remote Sensing of Environment*, 252:112162.

- Petropoulos, G. P., Ireland, G., Srivastava, P. K., and Ioannou-Katidis, P. (2014). An appraisal of the accuracy of operational soil moisture estimates from smos miras using validated in situ observations acquired in a mediterranean environment. *International Journal of Remote Sensing*, 35(13):5239–5250.
- Plag, H.-P., Rothacher, M., Pearlman, M., Neilan, R., and Ma, C. (2009). The global geodetic observing system. In *Advances in Geosciences: Volume 13: Solid Earth (SE)*, pages 105–127. World Scientific.
- Poropat, L., Dobslaw, H., Zhang, L., Macrandar, A., Boebel, O., and Thomas, M. (2018). Time variations in ocean bottom pressure from a few hours to many years: In situ data, numerical models, and grace satellite gravimetry. *Journal of Geophysical Research: Oceans*, 123(8):5612–5623.
- Rajner, M. and Liwosz, T. (2017). Analysis of seasonal position variation for selected gnss sites in poland using loading modelling and grace data. *Geodesy and Geodynamics*, 8(4):253–259.
- Ramillien, G., Frappart, F., and Seoane, L. (2014). Application of the regional water mass variations from grace satellite gravimetry to large-scale water management in africa. *Remote Sensing*, 6(8):7379–7405.
- Rashid, M. M., Sharma, A., and Johnson, F. (2020). Multi-model drought predictions using temporally aggregated climate indicators. *Journal of hydrology*, 581:124419.
- Reager, J., Gardner, A., Famiglietti, J., Wiese, D., Eicker, A., and Lo, M.-H. (2016). A decade of sea level rise slowed by climate-driven hydrology. *Science*, 351(6274):699–703.
- Reigber, C., Lühr, H., and Schwintzer, P. (2002). Champ mission status. *Advances in space research*, 30(2):129–134.
- Rieger, N., Corral, Á., Olmedo, E., and Turiel, A. (2021). Lagged teleconnections of climate variables identified via complex rotated maximum covariance analysis. *Journal of Climate*, 34(24):9861–9878.
- Ries, J., Bettadpur, S., Eanes, R., Kang, Z., Ko, U., McCullough, C., Nagel, P., Pie, N., Poole, S., Richter, T., et al. (2016). The combined gravity model ggm05c. *GFZ Data Services*.
- Rietbroek, R., Brunnabend, S.-E., Kusche, J., Schröter, J., and Dahle, C. (2016). Revisiting the contemporary sea-level budget on global and regional scales. *Proceedings of the National Academy of Sciences*, 113(6):1504–1509.
- Robinson, D. A., Campbell, C. S., Hopmans, J. W., Hornbuckle, B. K., Jones, S. B., Knight, R., Ogden, F., Selker, J., and Wendroth, O. (2008). Soil moisture measurement

- for ecological and hydrological watershed-scale observatories: A review. *Vadose Zone Journal*, 7(1):358–389.
- Rodell, M., Famiglietti, J. S., Wiese, D. N., Reager, J., Beaudoing, H. K., Landerer, F. W., and Lo, M.-H. (2018). Emerging trends in global freshwater availability. *Nature*, 557(7707):651–659.
- Rodell, M., Houser, P., Jambor, U., Gottschalck, J., Mitchell, K., Meng, C.-J., Arsenault, K., Cosgrove, B., Radakovich, J., Bosilovich, M., et al. (2004a). The global land data assimilation system. *Bulletin of the American Meteorological society*, 85(3):381–394.
- Rodell, M., Houser, P., Peters-Lidard, C., Kato, H., Kumar, S., Gottschalck, J., Mitchell, K., and Meng, J. (2004b). Nasa/noaa’s global land data assimilation system (gldas): Recent results and future plans. In *Proceedings of the ECMWF/ELDAS Workshop on Land Surface Assimilation, Shinfield, UK*, pages 8–11.
- Rodell, M., Velicogna, I., and Famiglietti, J. S. (2009). Satellite-based estimates of groundwater depletion in india. *Nature*, 460(7258):999–1002.
- Rothacher, M., Beutler, G., Behrend, D., Donnellan, A., Hinderer, J., Ma, C., Noll, C., Oberst, J., Pearlman, M., Plag, H.-P., et al. (2009). The future global geodetic observing system. In *Global Geodetic Observing System: Meeting the Requirements of a Global Society on a Changing Planet in 2020*, pages 237–272. Springer.
- Rzepecka, Z., Birylo, M., and Nastula, J. (2016). Assessment of resultant groundwater calculated on the basis of grace and gldas models. In *16th International Multidisciplinary Scientific GeoConference SGEM 2016 Conference Proceedings*, pages 125–132.
- Saha, S. (1995). Assessment of regional soil moisture conditions by coupling satellite sensor data with a soil-plant system heat and moisture balance model. *Remote Sensing*, 16(5):973–980.
- Sasgen, I., Konrad, H., Ivins, E., Van den Broeke, M., Bamber, J., Martinec, Z., and Klemann, V. (2013). Antarctic ice-mass balance 2003 to 2012: regional reanalysis of grace satellite gravimetry measurements with improved estimate of glacial-isostatic adjustment based on gps uplift rates. *The Cryosphere*, 7(5):1499–1512.
- Scanlon, B. R., Faunt, C. C., Longuevergne, L., Reedy, R. C., Alley, W. M., McGuire, V. L., and McMahon, P. B. (2012a). Groundwater depletion and sustainability of irrigation in the us high plains and central valley. *Proceedings of the national academy of sciences*, 109(24):9320–9325.
- Scanlon, B. R., Longuevergne, L., and Long, D. (2012b). Ground referencing grace satellite estimates of groundwater storage changes in the california central valley, usa. *Water*

Resources Research, 48(4).

Scanlon, B. R., Zhang, Z., Save, H., Sun, A. Y., Müller Schmied, H., Van Beek, L. P., Wiese, D. N., Wada, Y., Long, D., Reedy, R. C., et al. (2018). Global models underestimate large decadal declining and rising water storage trends relative to grace satellite data. *Proceedings of the National Academy of Sciences*, 115(6):E1080–E1089.

Schrama, E. J., Wouters, B., and Lavallée, D. A. (2007). Signal and noise in gravity recovery and climate experiment (grace) observed surface mass variations. *Journal of Geophysical Research: Solid Earth*, 112(B8).

Segal, M. R. (2004). Machine learning benchmarks and random forest regression.

Seitz, F., Schmidt, M., and Shum, C. (2008). Signals of extreme weather conditions in central europe in grace 4-d hydrological mass variations. *Earth and Planetary Science Letters*, 268(1-2):165–170.

Seo, K.-W., Ryu, D., Kim, B.-M., Waliser, D. E., Tian, B., and Eom, J. (2010). Grace and amsr-e-based estimates of winter season solid precipitation accumulation in the arctic drainage region. *Journal of Geophysical Research: Atmospheres*, 115(D20).

Seo, K.-W., Wilson, C., Famiglietti, J., Chen, J., and Rodell, M. (2006). Terrestrial water mass load changes from gravity recovery and climate experiment (grace). *Water Resources Research*, 42(5).

Seyoum, W. M., Kwon, D., and Milewski, A. M. (2019). Downscaling grace twsa data into high-resolution groundwater level anomaly using machine learning-based models in a glacial aquifer system. *Remote Sensing*, 11(7):824.

Seyoum, W. M. and Milewski, A. M. (2017). Improved methods for estimating local terrestrial water dynamics from grace in the northern high plains. *Advances in water resources*, 110:279–290.

Sheard, B., Heinzel, G., Danzmann, K., Shaddock, D., Klipstein, W., and Folkner, W. (2012). Intersatellite laser ranging instrument for the grace follow-on mission. *Journal of Geodesy*, 86(12):1083–1095.

Shibata, A., Imaoka, K., and Koike, T. (2003). Amsr/amsr-e level 2 and 3 algorithm developments and data validation plans of nasda. *IEEE transactions on geoscience and remote sensing*, 41(2):195–203.

Singh, P., Joshi, S. D., Patney, R. K., and Saha, K. (2017). The fourier decomposition method for nonlinear and non-stationary time series analysis. *Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 473(2199):20160871.

Śliwińska, J., Birylo, M., Rzepecka, Z., and Nastula, J. (2019). Analysis of groundwater

- and total water storage changes in poland using grace observations, in-situ data, and various assimilation and climate models. *Remote Sensing*, 11(24):2949.
- Śliwińska, J., Nastula, J., Dobslaw, H., and Dill, R. (2020a). Evaluating gravimetric polar motion excitation estimates from the rl06 grace monthly-mean gravity field models. *Remote Sensing*, 12(6):930.
- Śliwińska, J., Nastula, J., and Wińska, M. (2021a). Evaluation of hydrological and cryospheric angular momentum estimates based on grace, grace-fo and slr data for their contributions to polar motion excitation. *Earth, Planets and Space*, 73:1–20.
- Śliwińska, J., Wińska, M., and Nastula, J. (2020b). Preliminary estimation and validation of polar motion excitation from different types of the grace and grace follow-on missions data. *Remote Sensing*, 12(21):3490.
- Śliwińska, J., Wińska, M., and Nastula, J. (2021b). Validation of grace and grace-fo mascon data for the study of polar motion excitation. *Remote Sensing*, 13(6):1152.
- Solomatine, D. P. and Shrestha, D. L. (2004). Adaboost. rt: a boosting algorithm for regression problems. In *2004 IEEE International Joint Conference on Neural Networks (IEEE Cat. No. 04CH37541)*, volume 2, pages 1163–1168. IEEE.
- Spreen, G., Kaleschke, L., and Heygster, G. (2008). Sea ice remote sensing using amsr-e 89-ghz channels. *Journal of Geophysical Research: Oceans*, 113(C2).
- Sprott, J. C. and Sprott, J. C. (2003). *Chaos and time-series analysis*, volume 69. Oxford university press Oxford.
- Sun, A. Y. (2013). Predicting groundwater level changes using grace data. *Water resources research*, 49(9):5900–5912.
- Sun, A. Y., Scanlon, B. R., Save, H., and Rateb, A. (2021). Reconstruction of grace total water storage through automated machine learning. *Water Resources Research*, 57(2):e2020WR028666.
- Sun, A. Y., Scanlon, B. R., Zhang, Z., Walling, D., Bhanja, S. N., Mukherjee, A., and Zhong, Z. (2019). Combining physically based modeling and deep learning for fusing grace satellite data: can we learn from mismatch? *Water Resources Research*, 55(2):1179–1195.
- Sun, Q., Zhou, W.-X., and Fan, J. (2020a). Adaptive huber regression. *Journal of the American Statistical Association*, 115(529):254–265.
- Sun, Y., Ditmar, P., and Riva, R. (2016a). Observed changes in the earth’s dynamic oblateness from grace data and geophysical models. *Journal of geodesy*, 90:81–89.
- Sun, Y., Riva, R., and Ditmar, P. (2016b). Optimizing estimates of annual variations and trends in geocenter motion and j2 from a combination of grace data and geophysical

- models. *Journal of Geophysical Research: Solid Earth*, 121(11):8352–8370.
- Sun, Z., Long, D., Yang, W., Li, X., and Pan, Y. (2020b). Reconstruction of grace data on changes in total water storage over the global land surface and 60 basins. *Water Resources Research*, 56(4):e2019WR026250.
- Swenson, S., Chambers, D., and Wahr, J. (2008a). Estimating geocenter variations from a combination of grace and ocean model output. *Journal of Geophysical Research: Solid Earth*, 113(B8).
- Swenson, S., Famiglietti, J., Basara, J., and Wahr, J. (2008b). Estimating profile soil moisture and groundwater variations using grace and oklahoma mesonet soil moisture data. *Water Resources Research*, 44(1).
- Swenson, S. and Wahr, J. (2002). Methods for inferring regional surface-mass anomalies from gravity recovery and climate experiment (grace) measurements of time-variable gravity. *Journal of Geophysical Research: Solid Earth*, 107(B9):ETG–3.
- Swenson, S. and Wahr, J. (2006). Post-processing removal of correlated errors in grace data. *Geophysical research letters*, 33(8).
- Syed, T. H., Famiglietti, J. S., Rodell, M., Chen, J., and Wilson, C. R. (2008). Analysis of terrestrial water storage changes from grace and gldas. *Water Resources Research*, 44(2).
- Szelachowska, M., Godah, W., and Krynski, J. (2022). Contribution of grace satellite mission to the determination of orthometric/normal heights corrected for their dynamics—a case study of poland. *Remote sensing*, 14(17):4271.
- Szelachowska, M., Krynski, J., and Godah, W. (2017). On the estimation of physical height changes using grace satellite mission data—a case study of central europe. *Geodesy and Cartography*.
- Takashi Maeda, Y. T. (2013). Ndx-120015a descriptions of gcom-w1 amsr2 level 1r and level 2 algorithms. *Global Change Observation Mission Water*.
- Tang, J., Cheng, H., and Liu, L. (2014). Assessing the recent droughts in southwestern china using satellite gravimetry. *Water Resources Research*, 50(4):3030–3038.
- Tapley, B. D., Bettadpur, S., Ries, J. C., Thompson, P. F., and Watkins, M. M. (2004a). Grace measurements of mass variability in the earth system. *science*, 305(5683):503–505.
- Tapley, B. D., Bettadpur, S., Watkins, M., and Reigber, C. (2004b). The gravity recovery and climate experiment: Mission overview and early results. *Geophysical research letters*, 31(9).
- Tapley, B. D., Watkins, M. M., Flechtner, F., Reigber, C., Bettadpur, S., Rodell, M., Sasgen, I., Famiglietti, J. S., Landerer, F. W., Chambers, D. P., et al. (2019). Contributions

- of grace to understanding climate change. *Nature climate change*, 9(5):358–369.
- Theodosiou, M. (2011). Forecasting monthly and quarterly time series using stl decomposition. *International Journal of Forecasting*, 27(4):1178–1195.
- Tiwari, V. M., Wahr, J., and Swenson, S. (2009). Dwindling groundwater resources in northern india, from satellite gravity observations. *Geophysical Research Letters*, 36(18).
- Topp, G. C., Davis, J., and Annan, A. P. (1980). Electromagnetic determination of soil water content: Measurements in coaxial transmission lines. *Water resources research*, 16(3):574–582.
- Tregoning, P., McClusky, S., Van Dijk, A., Crosbie, R., and Peña-Arancibia, J. (2012). Assessment of grace satellites for groundwater estimation in australia. *National Water Commission, Canberra*, 82.
- Tropp, J. A. and Gilbert, A. C. (2007). Signal recovery from random measurements via orthogonal matching pursuit. *IEEE Transactions on information theory*, 53(12):4655–4666.
- Tscherning, C., Arabelos, D., and Strykowski, G. (2001). The 1-cm geoid after goce. In *Gravity, Geoid and Geodynamics 2000*, pages 267–270. Springer.
- Ulaby, F. T. (1982). Microwave remote sensing active and passive. *Rader remote sensing and surface scattering and emission theory*, pages 848–902.
- van der Vliet, M., van der Schalie, R., Rodriguez-Fernandez, N., Colliander, A., de Jeu, R., Preimesberger, W., Scanlon, T., and Dorigo, W. (2020). Reconciling flagging strategies for multi-sensor satellite soil moisture climate data records. *Remote Sensing*, 12(20):3439.
- Vaníček, P. (1969). Approximate spectral analysis by least-squares fit: Successive spectral analysis. *Astrophysics and Space Science*, 4:387–391.
- Vaníček, P. (1971). Further development and properties of the spectral analysis by least-squares. *Astrophysics and Space Science*, 12:10–33.
- Vereecken, H., Huisman, J., Pachepsky, Y., Montzka, C., Van Der Kruk, J., Bogaen, H., Weihermüller, L., Herbst, M., Martinez, G., and Vanderborght, J. (2014). On the spatio-temporal dynamics of soil moisture at the field scale. *Journal of Hydrology*, 516:76–96.
- Vinnikov, K. Y., Robock, A., Qiu, S., Entin, J. K., Owe, M., Choudhury, B. J., Hollinger, S. E., and Njoku, E. G. (1999). Satellite remote sensing of soil moisture in illinois, united states. *Journal of Geophysical Research: Atmospheres*, 104(D4):4145–4168.
- Vishwakarma, B. D., Bates, P., Sneeuw, N., Westaway, R. M., and Bamber, J. L. (2021a). Re-assessing global water storage trends from grace time series. *Environmental Research Letters*, 16(3):034005.

- Vishwakarma, B. D., Zhang, J., and Sneeuw, N. (2021b). Downscaling grace total water storage change using partial least squares regression. *Scientific data*, 8(1):95.
- Von Storch, H. and Zwiers, F. W. (2002). *Statistical analysis in climate research*. Cambridge university press.
- Voss, K. A., Famiglietti, J. S., Lo, M., De Linage, C., Rodell, M., and Swenson, S. C. (2013). Groundwater depletion in the middle east from grace with implications for trans-boundary water management in the tigris-euphrates-western iran region. *Water resources research*, 49(2):904–914.
- Wagner, W., Hahn, S., Kidd, R., Melzer, T., Bartalis, Z., Hasenauer, S., Figa, J., De Rosnay, P., Jann, A., Schneider, S., et al. (2013). The ascat soil moisture product: A review of its. *Meteorologische Zeitschrift*, 22(1):1–29.
- Wahr, J., Molenaar, M., and Bryan, F. (1998). Time variability of the earth’s gravity field: Hydrological and oceanic effects and their possible detection using grace. *Journal of Geophysical Research: Solid Earth*, 103(B12):30205–30229.
- Wang, J. and Forman, B. (2020). Improved terrestrial snow mass via multi-sensor assimilation of synthetic grace terrestrial water storage retrievals and synthetic amsr-e brightness temperature spectral differences. Technical report, Copernicus Meetings.
- Wang, J., Forman, B. A., Giroto, M., and Reichle, R. H. (2021). Estimating terrestrial snow mass via multi-sensor assimilation of synthetic amsr-e brightness temperature spectral differences and synthetic grace terrestrial water storage retrievals. *Water Resources Research*, 57(9):e2021WR029880.
- Wang, R., Huston, S., Li, Y., Ma, H., Peng, Y., and Ding, L. (2018). Temporal stability of groundwater depth in the contemporary yellow river delta, eastern china. *Sustainability*, 10(7):2224.
- Watkins, M. M., Wiese, D. N., Yuan, D.-N., Boening, C., and Landerer, F. W. (2015). Improved methods for observing earth’s time variable mass distribution with grace using spherical cap mascons. *Journal of Geophysical Research: Solid Earth*, 120(4):2648–2671.
- Wen, H. Y., Kruizinga, G., Paik, M., Landerer, F., Bertiger, W., Sakumura, C., Bandikova, T., and McCullough, C. (2019). Gravity recovery and climate experiment follow-on (grace-fo) level-1 data product user handbook.
- West, M. (1997). Time series decomposition. *Biometrika*, 84(2):489–494.
- Wigneron, J.-P., Kerr, Y., Waldteufel, P., Saleh, K., Escorihuela, M.-J., Richaume, P., Ferrazzoli, P., De Rosnay, P., Gurney, R., Calvet, J.-C., et al. (2007). L-band microwave emission of the biosphere (l-meb) model: Description and calibration against experimental

- data sets over crop fields. *Remote Sensing of Environment*, 107(4):639–655.
- Wilby, R. L., Wigley, T., Conway, D., Jones, P., Hewitson, B., Main, J., and Wilks, D. (1998). Statistical downscaling of general circulation model output: A comparison of methods. *Water resources research*, 34(11):2995–3008.
- Wilby, R. L. and Wigley, T. M. (1997). Downscaling general circulation model output: a review of methods and limitations. *Progress in physical geography*, 21(4):530–548.
- Wouters, B., Gardner, A. S., and Moholdt, G. (2019). Global glacier mass loss during the grace satellite mission (2002-2016). *Frontiers in earth science*, 7:96.
- Wouters, B. and Schrama, E. J. (2007). Improved accuracy of grace gravity solutions through empirical orthogonal function filtering of spherical harmonics. *Geophysical Research Letters*, 34(23).
- Xu, M., Watanachaturaporn, P., Varshney, P. K., and Arora, M. K. (2005). Decision tree regression for soft classification of remote sensing data. *Remote Sensing of Environment*, 97(3):322–336.
- Yin, G. and Park, J. (2021). The use of triple collocation approach to merge satellite-and model-based terrestrial water storage for flood potential analysis. *Journal of Hydrology*, 603:127197.
- Yin, W., Hu, L., Zhang, M., Wang, J., and Han, S.-C. (2018). Statistical downscaling of grace-derived groundwater storage using et data in the north china plain. *Journal of Geophysical Research: Atmospheres*, 123(11):5973–5987.
- Yoo, C. and Kim, S. (2004). Eof analysis of surface soil moisture field variability. *Advances in Water Resources*, 27(8):831–842.
- Yuan, D.-N. (2018). Grace d-103922 gravity recovery and climate experiment follow-on (grace-fo). *Level-2 Gravity Field Product User Handbook*.
- Zaitchik, B. F., Rodell, M., and Reichle, R. H. (2008). Assimilation of grace terrestrial water storage data into a land surface model: Results for the mississippi river basin. *Journal of Hydrometeorology*, 9(3):535–548.
- Zaremba, W., Sutskever, I., and Vinyals, O. (2014). Recurrent neural network regularization. *arXiv preprint arXiv:1409.2329*.
- Zhao, M., Geruo, A., Velicogna, I., and Kimball, J. S. (2017a). A global gridded dataset of grace drought severity index for 2002–14: comparison with pdsi and spei and a case study of the australia millennium drought. *Journal of Hydrometeorology*, 18(8):2117–2129.
- Zhao, M., Velicogna, I., and Kimball, J. S. (2017b). Satellite observations of regional drought severity in the continental united states using grace-based terrestrial water storage

changes. *Journal of Climate*, 30(16):6297–6308.

10 Załączniki

10.1 Lista załączników

- [1] Oświadczenia o udziale autorskim publikacja [1]
- [2] Oświadczenia o udziale autorskim publikacja [2]
- [3] Oświadczenia o udziale autorskim publikacja [3]
- [4] Oświadczenia o udziale autorskim publikacja [4]
- [5] Oświadczenia o udziale autorskim publikacja [5]
- [6] Publikacja [1]
- [7] Publikacja [2]
- [8] Publikacja [3]
- [9] Publikacja [4]
- [10] Publikacja [5]

10.2 Załączniki

Oświadczenie o udziale autorskim

Publikacja [1]:

Kuczynska-Siehien, J., Piretzidis, D., Sideris, M. G., Olszak, T. and Szabó, V. (2019) 'Monitoring of extreme land hydrology events in central Poland using GRACE, land surface models and absolute gravity data', Journal of Applied Geodesy, Vol. 13, No. 3, pp.229-243, doi: 10.1515/jag-2019-0003.

100 pkt MEiN; IF: 1.30

Autor	Udział	Zadania	Podpis
Kuczynska-Siehien, J.	30%	- Przygotowanie koncepcji badań, - Przegląd literatury, - Opracowanie danych, - Analiza wyników, - Dyskusja wyników i wnioski. - Przygotowanie oryginalnej wersji artykułu, - Korekta na podstawie otrzymanych recenzji - Zatwierdzenie ostatecznej wersji artykułu.	Joanna Kuczynska-Siehien
Piretzidis, D.	25%		
Sideris, M. G.	10%		
Olszak, T.	25%	- Udział w przygotowaniu koncepcji i metodyki badań, - Opracowanie danych z grawimetrycznych pomiarów absolutnych, - Krytyczna recenzja i redagowanie oryginalnej wersji artykułu, - Wsparcie na etapie korekty artykułu na podstawie otrzymanych recenzji, - Zatwierdzenie ostatecznej wersji artykułu.	Tomasz Olszak
Szabó, V.	10%	Przygotowanie danych z misji GRACE, napisanie skryptu umożliwiającego filtrowanie danych współczynników sferycznych harmonicznych poziomu 2 filtrami nie-izotropowymi DDK1-8.	Viktor Szabó

Oświadczenie o udziale autorskim

Publikacja [2]:

Szabó, V. and Marjańska, D. (2020) 'Accuracy analysis of gravity field changes from GRACE RL06 and RL05 data compared to in situ gravimetric measurements in the context of choosing optimal filtering type', Artificial Satellites: Journal of Planetary Geodesy, Vol. 55, No. 3, pp.100–117, doi: 10.2478/arsa-2020-0008.

70 pkt MEiN; IF: 0.90

Autor	Udział	Zadania	Podpis
Szabó, V.	80%	• Przygotowanie danych, • Praca nad koncepcją i metodyką badań, przeprocesowanie i analiza rozwiązań, • Przegląd literatury, • Przygotowanie całej treści artykułu w języku polskim. • Korekta artykułu na podstawie recenzji.	Viktor Szabó
Marjańska, D.	20%	• tłumaczenie tekstu manuskryptu z języka polskiego na angielski, • przygotowanie odpowiedzi dla recenzentów,	Marjańska

Oświadczenie o udziale autorskim

Publikacja [3]:

Szabó, V (2023) 'Comparison features importance for temporal and spatial-temporal approaches in GRACE and GRACE-FO signal reconstruction based on GLDAS data', International Journal of Hydrology Science and Technology, doi: 10.1504/IJHST.2023.134623

100 pkt MEiN; IF: 1.80

Autor	Udział	Zadania	Podpis
Szabó, V.	100%	• Przygotowanie koncepcji i metodyki badań, • Przegląd literatury, • Napisanie kodu umożliwiającego analizę rozwiązań, • Opracowanie danych, • Analiza wyników, • Dyskusja wyników i wnioski. • Przygotowanie oryginalnej wersji artykułu, • Korekta artykułu na podstawie otrzymanych recenzji.	Viktor Szabó

Oświadczenie o udziale autorskim

Publikacja [4]:

Szabó, V. and Osińska-Skotak, K. (2023) 'Similarities and differences in the Earth's water variations signal provided by GRACE and AMSR-E observations using Maximum Covariance Analysis at various Land Cover data backgrounds', Artificial Satellites: Journal of Planetary Geodesy, Vol. 58, No. 2 - 2023, doi: 10.2478/arsa-2023-0006

70 pkt MEiN; IF: 0.90

Autor	Udział	Zadania	Podpis
Szabó, V.	85%	• Przygotowanie koncepcji i metodyki badań, • Przegląd literatury, • Napisanie kodu umożliwiającego analizę rozwiązań, • Opracowanie danych, • Analiza wyników, • Dyskusja wyników i wnioski. • Przygotowanie oryginalnej wersji artykułu, • Korekta artykułu na podstawie otrzymanych recenzji.	Viktor Szabó
Osińska-Skotak, K.	15%	• Udział w przygotowaniu koncepcji i metodyki badań, • Krytyczna recenzja i redagowanie oryginalnej wersji artykułu, • Wsparcie na etapie korekty artykułu na podstawie otrzymanych recenzji. • Zatwierdzenie ostatecznej wersji artykułu.	K. Osińska-Skotak

Oświadczenie o udziale autorskim

Publikacja [5]:

Szabó, V., Osińska-Skotak, K. and Olszak, T. (2024) 'Using machine learning techniques to reconstruct the signal observed by the GRACE mission based on AMSR-E microwave data', *Miscellanea Geographica - Regional Studies on Development*, Vol. 28, No. 2 - 2024, doi: 10.2478/mgrsd-2023-0033

100 pkt MEiN; IF: 0.80

Autor	Udział	Zadania	Podpis
Szabó, V.	80%	• Przygotowanie koncepcji badań, • Przegląd literatury, • Napisanie kodu umożliwiającego analizę rozwiązań, • Opracowanie danych, • Analiza wyników, • Dyskusja wyników i wnioski. • Przygotowanie oryginalnej wersji artykułu, • Korekta na podstawie otrzymanych recenzji.	Viktor Szabó
Osińska-Skotak, K.	12%	• Udział w przygotowaniu koncepcji i metodyki badań, • Krytyczna recenzja i redagowanie oryginalnej wersji artykułu, • Wsparcie na etapie korekty artykułu na podstawie otrzymanych recenzji, • Zatwierdzenie ostatecznej wersji artykułu.	K. Osińska-Skotak
Olszak, T.	8%	• Udział w przygotowaniu koncepcji i metodyki badań, • Krytyczna recenzja i redagowanie oryginalnej wersji artykułu, • Wsparcie na etapie korekty artykułu na podstawie otrzymanych recenzji, • Zatwierdzenie ostatecznej wersji artykułu.	Tomasz Olszak

Joanna Kuczynska-Siehien*, Dimitrios Piretzidis, Michael G. Sideris, Tomasz Olszak, and Viktor Szabó

Monitoring of extreme land hydrology events in central Poland using GRACE, land surface models and absolute gravity data

<https://doi.org/10.1515/jag-2019-0003>

Received January 15, 2019; accepted March 28, 2019

Abstract: This study deals with the analysis of temporal gravity variations in central Poland, deduced from multiple sources and covering the period from 2002–2016. The gravity data sets used comprise GRACE monthly solutions, GLDAS land surface models and absolute gravimeter measurements from the FG-5 gravimeter located in Józefosław, Poland. All data are corrected using standard processing methods in order to include the same gravity effects. After removing the annual and semi-annual components from all data using least-squares spectral analysis and seasonal-trend decomposition, the deseasoned time series are derived and examined for signatures of extreme hydrological events. The signatures of several severe drought and flood conditions affecting Poland and central Europe are identified. A complementary correlation analysis is performed to assess the level of agreement between different data sources. A higher correlation is shown when the analysis is restricted in the 2009–2012 period that includes the 2010 extreme flood and 2011 increased precipitation events, both affecting Poland.

Keywords: Temporal gravity variations, Local hydrology, Flood monitoring, GRACE, GLDAS, Absolute gravimeter

1 Introduction

The main geophysical process contributing to spatiotemporal gravity changes on global scale is the redistribution of water masses. This led to an increase of land hydrology studies that utilize gravity data and the development of improved land hydrology models by assimilating gravity data into already existing models [1–3]. The accurate monitoring of gravity field changes on global scale and with uniform coverage can be performed only by the Gravity Recovery and Climate Experiment (GRACE; [4]) twin-satellite system. GRACE mission was launched in March 2002 and ended in October 2017, providing monthly gravity field solutions for fifteen years with sporadic interruptions.

Amongst the numerous applications of GRACE, monitoring extreme hydrological events, such as droughts and floods, is of major importance. Groundwater depletion and drought conditions are repeatedly reported for northern India [5], [6], China [7], [8], the Middle East [9], [10] and California Central Valley [11–13]. In central Europe, Andersen et al. [14] identified signatures of the 2003 heat wave in GRACE data that were also corroborated by superconducting gravimeter measurements, hydrology models and water-balance estimates. Increased terrestrial water storage (TWS) trends and extreme flood events are also documented by previous studies using GRACE data. The influence of extreme weather conditions in GRACE-derived equivalent water height (EWH) in central Europe using wavelet analysis is studied in [15]. They identified signatures of high precipitation events and dry seasons, and demonstrated the high correlation of GRACE models with atmospheric and hydrological data. Chen et al. [16] analyzed GRACE-derived EWH changes to study the spatial and temporal evolution of the 2009 exceptional Amazon flood. Vishwakarma et al. [17] investigated the potential of GRACE to detect floods of limited spatiotemporal extent by analyzing time series of EWH residuals. More recently, Gouweleeuw et al. [18] used daily GRACE solutions to monitor the major flood events in the Ganges-Brahmaputra Delta during 2004 and 2007.

Although many studies have been performed on the evaluation of extreme hydrological events using GRACE,

***Corresponding author: Joanna Kuczynska-Siehien**, Department of Geomatics Engineering, University of Calgary, 2500 University Dr NW, Calgary, AB T2N 1N4, Canada; and Faculty of Geodesy, Geospatial and Civil Engineering, University of Warmia and Mazury in Olsztyn, Oczapowskiego 2, Olsztyn, Poland, e-mail: joanna.kuczynska@uwm.edu.pl, ORCID: <https://orcid.org/0000-0001-7444-4753>

Dimitrios Piretzidis, Michael G. Sideris, Department of Geomatics Engineering, University of Calgary, 2500 University Dr NW, Calgary, AB T2N 1N4, Canada, e-mails: dimitrios.piretzidis@ucalgary.ca, sideris@ucalgary.ca, ORCID: <https://orcid.org/0000-0003-0148-8063> (D. Piretzidis)

Tomasz Olszak, Viktor Szabó, Faculty of Geodesy and Cartography, Warsaw University of Technology, Plac Politechniki 1, 00-661, Warszawa, Poland, e-mails: tomasz.olszak@pw.edu.pl, Viktor.Szabo@pw.edu.pl

there is a gap in the published literature concerning such events in central Europe during the recent decade. The main objective of our study is to detect and monitor extreme hydrological events in east-central Poland from 2002 to 2016 and investigate their gravity signatures. We analyze time series of gravity changes coming from three independent sources, i. e., GRACE monthly solutions, Global Land Data Assimilation System (GLDAS; [19]) monthly models and absolute gravimeter measurements. GLDAS models provide global grids of numerous land hydrology parameters at different spatial and temporal scales. GLDAS also incorporates four different land surface models (LSMs), namely, the Community Land Model (CLM), Mosaic, Noah and Variable Infiltration Capacity (VIC) LSMs. Since the first GRACE solutions became available, GLDAS data are routinely compared with the former in hydrological studies with a fairly good level of agreement [20–24]. The absolute gravimeter measurements are obtained from the gravimetric station at the Astro-Geodetic Observatory (AGO) in Józefosław (Figure 1), located in the center of our study area. The gravimetric station operates since 2005, resulting in the longest time series of gravity measurements in Poland at this time [25]. Absolute gravity measurements have been used in the past, together with GRACE and hydrology models, to compare temporal gravity variations and validate GRACE data [26–29].




Figure 1: Location of the Astro-Geodetic Observatory in Józefosław, Poland.

2 Data and methods

2.1 Absolute gravity data

2.1.1 Gravimeter site and study area

The FG-5 no. 230 absolute gravimeter, installed on a pillar in the basement of the main AGO building, is used to deter-

mine absolute gravity values at monthly intervals. The pillar is located 5.7 meters below ground level. The gravimeter's total uncertainty is $2\mu\text{Gal}$ and is comparable with the accuracy of the GRACE-derived gravity field series, which is at the level of a few μGal . A better accuracy in gravity measurements can be achieved only by using superconducting gravimeters. In addition to gravimetric observations, the AGO monitors the changes in environmental conditions, including the groundwater level, around the gravity station [25]. The groundwater level is measured by a piezometer and ranges from approximately -8 to -12 meters. The hydro-geological situation near the gravimetric station is shown in Figure 2 and represents a typical structure for quaternary post-glacial sediments with sands accumulated on boulder clays.

2.1.2 Influence of local site effects

Gravimeters are more sensitive to temporal gravity variations occurring in their immediate surroundings because gravity magnitude is inversely proportional to the squared distance from the attracting masses. Local site effects should therefore be studied in order to validate geometric assumptions made in the gravity processing (e.g., Bouguer slab approximation) and be taken into account for the accurate interpretation of gravity changes. The most important local site effects, also highlighted in previous studies, are the topography and building housing. In case the surrounding ground surface is above the gravimeter site (i. e., gravimeter located next to a hill), water storage changes occurring at shallow depth result in negative gravity response. The spatial distribution of water storage changes are also directly affected by buildings. Building roofs prevent rain water from directly infiltrating the area beneath the building [31]. This is known as “umbrella” effect [32]. The foundation of a building also forms a zone where no water storage change occurs. The studies of [31] and [33], focused entirely on the correction of local site effects, are based on in-situ data (e.g., elevation, soil moisture and evapotranspiration) and advanced modeling of the hydrological processes in the surrounding area. Due to the absence of in-situ hydrological data around the gravimeter site and limited knowledge of the very local hydrogeology, local site effects in the AGO region are taken into account using a simplified approach based on [31].

In order to examine the influence of the topography, digital elevation model (DEM) data from the Polish Geoportal of Spatial Information Infrastructure are used. The DEM data provide normal heights in a rectangular grid with a spatial resolution of 100 meters. The grid coordi-




Figure 2: Scheme of geological profile in Józefosław (reproduction based on [30]).

nates refer to the State Geodetic Coordinate System 1992 (PUWG1992) and the elevation data to the Kronsztadt86 local vertical datum. Figure 3a shows the elevation differences with respect to gravimeter site around an area of 2.5 by 2.5 km. In the closer vicinity of a few hundred meters around the gravimeter site, elevation differences do not exceed one meter and the area can be characterized as almost flat. The effect of the topography on measured gravity is quantified by comparing the gravity response of a 1 m water mass change occurring on the topographic surface with the response of the same mass change occurring on an infinite slab (Bouguer plate). The ratio of the resulting gravity responses, denoted as C_{topo} , is equal to one for an entirely flat terrain [31]. Before calculating C_{topo} , the DEM spatial resolution is artificially increased to 25 meters using cubic interpolation to avoid step effects. The DEM data are also corrected for the curvature of the equipotential surfaces, as follows [34]:

$$h_{corr} = h_{DEM} - \frac{1}{2R}d^2, \quad (1)$$

where h_{corr} and h_{DEM} is the corrected and original normal height, R is the Earth's equatorial radius and d is the horizontal distance of each grid cell from the gravimeter location. The gravity response for the evaluation of C_{topo} is calculated using rectangular prisms as mass elements [35], [36]. The gravity effect of each water prism is given in Figure 3b. Negative gravity values denote that prisms are located higher than the gravimeter site. The maximum curvature at the area of Figure 3 is approximately 1 meter, resulting in a gravity response of $0.01 \mu\text{Gal}$. Therefore, the effect of the curvature of the equipotential surface is negligible for such local cases. Given the results of Figure 3b, 99 % of the gravity response is produced by water masses inside a radius of 125 meters. The ratio C_{topo} is equal to 0.99, which denotes an almost flat terrain.

For the building umbrella effect, the gravity response of a 1 m water mass change occurring in an area that

matches the building shape is compared with the response of an infinite slab. The ratio of the two gravity responses, denoted as C_{bldg} , is close to one when the building has a significant effect on the signal sensed by the gravimeter. C_{bldg} depends on the building footprint and shape, and the location of the gravimeter relative to the building. The AGO building is mostly rectangular with a rotunda-shaped room (dotted circle in Figure 4) of 3.8 meters radius located in the center, across the main entrance. The rotunda is approximated by a square of 7.6 by 7.6 meters and the rest of the building is divided into three additional rectangles, given in Figure 4. The building footprint covers a total area of 630 m^2 . The gravity response at the gravimeter location is calculated by adding the gravity response of the four prisms in Figure 4. The ratio C_{bldg} is equal to 0.93, indicating that the umbrella effect is significant. More advanced methods for accounting building effects are given in [33]. The total influence of local site effects $C_{total} = C_{topo} - C_{bldg}$ is equal to 0.06 for the gravimeter located at the AGO building.

2.1.3 Gravimeter data processing

All absolute gravity values are corrected for the well-known gravity effects due to Earth and ocean tides, pole tide and atmospheric pressure. Tidal effects are calculated using the ETGTAB software [37] with the tidal potential catalog of [38], and the FES2004 ocean tide model [39]. For the polar motion correction, mean pole coordinates from Bulletin B of Earth Orientation Center are interpolated to the mean epoch of each gravity session. Atmospheric correction is applied based on the pressure differences from the gravity station height, using a value of $0.3 \mu\text{Gal}/\text{mbar}$. Instrumental corrections such as the reduction to the constant height with measured vertical gravity gradient and the absolute reference level offset, determined during the




Figure 3: (a) Elevation differences with respect to gravimeter site. (b) Contribution of gravity response from a water mass change of 1 m at the gravimeter site, calculated for each prismatic body.




Figure 4: Approximate layout of AGO building for the calculation of C_{bldg} . The yellow triangle shows the gravimeter location and the red triangle the main entrance.




Figure 6: Time series of hydrological loading in terms of gravity. Light color denotes the complete time series, while dark color the values interpolated to the gravimeter measurement epochs.




Figure 5: Gravity change and groundwater level change at the AGO.

ICAG/ECAG International Comparison campaigns, are applied. The time series of the observed gravity and groundwater level change, after a long-term mean is removed, are shown in Figure 5. The time series exhibits time gaps around 2009, 2012, 2013 and 2014 related to the gravimeter maintenance.

We additionally use the surface gravity products of the EOST Loading Service [40] to include the hydrological loading in the gravimeter time series. This procedure is explained later in the paper. The hydrological loading is estimated from the GLDAS Noah v. 2.1 model. The spatial and temporal resolution of GLDAS Noah v. 2.1 are 0.25° and 3 hours, respectively. The EOST service provides time series of surface gravity change that account for the influence of local and non-local hydrology, presented in Figure 6 after removing seasonal components. GLDAS data do not model groundwater, therefore the time series of Figure 6 correspond mainly to surface hydrological processes.

The absolute gravimeter measurements are not directly comparable with GRACE- and GLDAS-derived estimates of gravity changes for two main reasons: (a) the gravimeter is located below the Earth's surface and (b) the gravimeter measurements contain local hydrology signals. Gravimeters located in underground stations provide a sig-

nal influenced by masses from both above and below the sensor. The resulting attraction of these two components oppose each other [28]. In such cases, it is more difficult to interpret gravity changes and infer conclusions about occurring geophysical events. Correct interpretation is possible only by accurately modeling the geological structure and the hydrological events of the region. Here we discuss a simpler approach to account for the gravimeter location. First, we distinguish two components that form the resulting gravity measured by the gravimeter. The first component (surface component) includes the attraction from the solid masses (g_{s1}) and water masses (g_{h1}) above the gravimeter. If the gravimeter is located a few meters below ground, g_{h1} is mainly coming from soil moisture, water stored in canopy and surface water. Local site effects are also included in the surface component. The second component (deep component) comprises the attraction from solid masses (g_{s2}) and water masses (g_{h2}) below the gravimeter. The constituent g_{h2} is mostly due to underground water [31]. The resulting attraction measured by the gravimeter is (Figure 7a):

$$g = g_{s2} + g_{h2} - g_{s1} - g_{h1}. \quad (2)$$

The corresponding gravity measured by a gravimeter on the Earth's surface would be (Figure 7b):

$$g' = g'_{s2} + g'_{h2} + g_{s1} + g_{h1}, \quad (3)$$

where prime denotes quantities measured on the surface. When the gravity changes are studied, and assuming that the soil mass distribution is constant ($\Delta g_{s1} = 0$, $\Delta g_{s2} = 0$), the conversion of Δg to $\Delta g'$ is done as follows:

$$\Delta g' = \Delta g + 2\Delta g_{h1}. \quad (4)$$

The surface water mass change Δg_{h1} is estimated here using the EOST hydrological loading data and is equal to the sum of the local and non-local contribution, denoted as




Figure 7: Gravity components sensed by a gravimeter located (a) below and (b) above the ground.

Δg_{h1}^l and Δg_{h1}^{nl} , respectively. The local contribution is calculated by the EOST service using a simple Bouguer approximation and needs to be corrected for local site effects, whereas the non-local contribution is calculated using Greens function [41]. After correcting the local contribution for deviations from the Bouguer approximation due to local site effects, Eq. (4) takes the following form:

$$\Delta g' = \Delta g + 2(C_{total}\Delta g_{h1}^l + \Delta g_{h1}^{nl}) \quad (5)$$

After correcting for the gravimeter location, we account for local hydrology effects. Local influences of water storage changes at shallow depth are removed using the local contribution of EOST hydrological loading. The corrected gravity changes, after applying the local site effect correction are:

$$\Delta g_{c1} = \Delta g' - C_{total}\Delta g_{h1}^l. \quad (6)$$

Local effects of groundwater storage changes are removed using the available in-situ groundwater level changes. Assuming that a change of Δh in the groundwater level results in a change of Δg_{hyd} in the measured gravity based on the relation [42]:

$$\Delta g_{hyd} = 41.92S_y\Delta h, \quad (7)$$

the impact of local groundwater changes on gravity can be calculated by estimating the specific yield coefficient S_y using linear regression. The true value of specific yield S_y depends on the hydrogeology of the study area (e. g., water properties of underground material). In practice, the estimation of S_y also depends on instrument uncertainties. Absolute gravimeter uncertainties are usually one or sometimes two orders of magnitude greater than superconducting gravimeter uncertainties. Wilson et al. [42] state that superconducting gravimeters can sense storage changes equivalent to a 2-mm water layer, whereas other types of gravimeters are only able to sense changes that exceed the equivalent to a 40-mm water layer. Therefore, the S_y estimate of our study might not be in good agreement with previous studies that use superconducting gravimeters. After calculating a specific yield $S_y = 0.13$ (slope of best fitting line in Figure 8), the corrected gravity Δg_c will be given by:

$$\Delta g_c = \Delta g_{c1} - \Delta g_{hyd}. \quad (8)$$

2.2 GRACE

We use the RL06 of GRACE monthly solutions, distributed by the Center for Space Research (CSR) and the Jet Propulsion Laboratory (JPL), from August 2002 to December 2016. RL06 solutions from the GeoForschungsZentrum (GFZ)




Figure 8: Scatter plot of FG-5 gravity changes, corrected for gravimeter location and local hydrology at shallow depth, and groundwater level changes.

were not included because they were only provided up to 2011 during the preparation of our analysis. GRACE monthly solutions (Level 2 products) are in the form of Stokes coefficients $C_{n,m}$ and $S_{n,m}$ of degree n and order m . Degree-1 coefficients ($C_{1,0}$, $C_{1,1}$ and $S_{1,1}$) obtained from Dr. Don Chambers and Dr. Jeniffer Bonin, University of South Florida, are added to GRACE monthly solutions to account for geocenter variations [43]. $C_{2,0}$ coefficients are replaced by SLR-derived ones [44]. $C_{2,1}$ and $S_{2,1}$ coefficients are corrected for pole tide effects using the methodology of Wahr et al. [45]. The viscoelastic response of the solid Earth to the melting of ice masses from the last glacial maximum is not expected to have significant influence in our study area, therefore, no glacial isostatic adjustment (GIA) correction is applied. Stokes coefficient changes $\Delta C_{n,m}$ and $\Delta S_{n,m}$ are calculated by removing the GGM05C static gravity field [46] from each monthly solution. Coefficient changes mainly represent mass redistribution due to hydrological events but are highly affected by correlated errors. These errors are suppressed by selectively applying the empirical decorrelation filter of Swenson and Wahr [47] using the methodology of Piretzidis et al. [48]. The selective decorrelation is performed using the SHADE toolbox [49]. A 300-km Gaussian filter [50] is also applied to the decorrelated coefficient changes. The gravity changes Δg of a point with spherical coordinates (r, θ, λ) are expressed in spherical harmonic expansion as follows [26]:

$$\Delta g(r, \theta, \lambda) = \frac{1}{r} \frac{GM}{R} \sum_{n=0}^{n_{\max}} \left(\frac{R}{r} \right)^{n+1} (n+1) \sum_{m=0}^n \bar{P}_{n,m}(\cos \theta) \times (\Delta C_{n,m}^f \cos m\lambda + \Delta S_{n,m}^f \sin m\lambda), \quad (9)$$

where GM is the Earth's standard gravitational parameter, R is the Earth's radius, $\bar{P}_{n,m}$ are the normalized associated Legendre functions and the superscript f denotes filtered

coefficient changes. The gravity changes Δg_s of a point on the Earth's surface (i. e., $r = R$) are computed by taking into account the Earth's elastic deformation due to loading [28]:

$$\Delta g_s(\theta, \lambda) = \frac{GM}{R^2} \sum_{n=0}^{n_{\max}} \left(n+1 - \frac{2h_n}{1+k_n} \right) \sum_{m=0}^n \bar{P}_{n,m}(\cos \theta) \times (\Delta C_{n,m}^f \cos m\lambda + \Delta S_{n,m}^f \sin m\lambda), \quad (10)$$

where h_n and k_n are the Love numbers, taken from [51]. The value of k_1 is changed to 0.021 to account for the included GRACE geocenter variations. Monthly grids of Δg_s are calculated with a spatial resolution of 1° , and a spatial average is calculated for each epoch by taking into account grid points inside a radius of 250 km around Józefosław. We also calculate a scale factor for the conversion of Δg to Δg_s using linear regression. The scale factor corresponds to the slope of the best fitting line in Figure 9(a) and is equal to 1.36 for both GRACE data sets. This value is in close agreement with the value of 1.35 calculated by Neumeyer et al. [27], although they did not take into account the effect of k_n . Crossley et al. [28] also found similar scale factors (1.34 for GRGS solutions, 1.36 and 1.39 for CSR solutions using different filtering techniques). The spatial averages of Δg_s are corrected for filter-induced signal damage using a simple basin-scale gain factor of 1.06. This factor is derived by a simulation using the four GLDAS LSMs and the methodology of Landerer and Swenson [52]. The basin-scale gain factor is shown as the slope of the best fitting line in Figure 9(b). The GRACE-derived Δg_s time series, after filtering and rescaling, is presented in Figure 10.

2.3 Land surface models

The four GLDAS LSMs cover the period from January 2002 to December 2016. Global grids of TWS are calculated using the output components of average layer soil moisture, total canopy water storage and snow water equivalent from each LSM. TWS changes are derived by removing a long term mean from each monthly TWS grid. The TWS changes are converted into mass change coefficients $\{\Delta \hat{C}_{n,m}^{hyd}, \Delta \hat{S}_{n,m}^{hyd}\}$ using global spherical harmonic analysis, and then into Stokes coefficient changes using [53]:

$$\begin{Bmatrix} \Delta \hat{C}_{n,m}^{hyd} \\ \Delta \hat{S}_{n,m}^{hyd} \end{Bmatrix} = \frac{3\rho_w}{\rho_{ave}} \frac{1+k_n}{2n+1} \begin{Bmatrix} \Delta \hat{C}_{n,m}^{hyd} \\ \Delta \hat{S}_{n,m}^{hyd} \end{Bmatrix}, \quad (11)$$

where ρ_w and ρ_{ave} denote water density and the Earth's average density, respectively. The coefficient changes derived from Eq. (11) are also filtered with a 300-km Gaussian filter and used in Eq. (10) to calculate GLDAS-derived gravity




Figure 9: (a) Scatter plot of GRACE Δg and Δg_s calculated on the Earth's surface. (b) Scatter plot of filtered and unfiltered GLDAS Δg_s .




Figure 10: GRACE-derived Δg_s .




Figure 11: GLDAS-derived Δg_s .

changes on the Earth's surface. The results after performing spatial averaging are shown in Figure 11.

2.4 Removal of periodic variations

Periodic variability of land hydrology is usually the predominant signal in GRACE time series. The annual and

semi-annual variations that comprise the periodic constituent of gravity changes, denoted as $\widetilde{\Delta g_s}$, should be removed in order to reveal signatures of extreme hydrological events. The reduced time series of gravity changes, given by:

$$\Delta g_r(t) = \Delta g_s(t) - \widetilde{\Delta g_s}(t), \quad (12)$$

with $t = t_1, \dots, t_N$ to denote the time epoch, contains possible periodic signals with period $T = 3$ months and $T > 1$ year, non-periodic signals and noise. Due to the presence of gaps in the analyzed GRACE time series, the annual and semi-annual signals are computed using two methods, i.e., least-squares spectral analysis (LSSA) and seasonal trend decomposition using local regression (STL). Another frequently used method to isolate and examine seasonal patterns in time series is the use of empirical orthogonal function (EOF) decomposition. The studies [27], [28] and [29] provide good examples of comparison analysis between GRACE-derived gravity variations with superconducting gravimeter observations in several European sites using EOF decomposition. EOF decomposition is not preferred in this study due to time gaps in GRACE time series.

LSSA [54], [55] is a method of spectrum estimation by fitting sinusoids of known periods to the observed data. Utilizing the concept of least-squares fit makes LSSA an appropriate tool for studying unevenly spaced time series or time series with gaps. We use LSSA to approximate the annual and semi-annual signals with the weighted sum of two pairs of sinusoids with periods $T_a = 1$ and $T_s = 0.5$ years, respectively, and simultaneously estimate a bias a and a long-term trend b . In this case, the periodic signal can be expressed using the following linear model:

$$\begin{aligned}\widehat{\Delta g_s}(t) = & a + bt + c_a \cos \frac{2\pi t}{T_a} + d_a \sin \frac{2\pi t}{T_a} \\ & + c_s \cos \frac{2\pi t}{T_s} + d_s \sin \frac{2\pi t}{T_s},\end{aligned}\quad (13)$$

where c_a and c_s are the cosine weights, d_a and d_s are the sine weights, and the subscripts “a” and “s” denote the annual and semi-annual signal, respectively. Optimal values for the unknown parameters a , b , c_a , d_a , c_s and d_s are estimated from the well-known least-squares method:

$$\hat{\mathbf{x}} = (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T \mathbf{y}, \quad (14)$$

where the optimally estimated vector of unknown parameters $\hat{\mathbf{x}}$, the observation vector $\mathbf{y}$ and the design matrix $\mathbf{A}$ are as follows:

$$\hat{\mathbf{x}} = [\hat{a} \quad \hat{b} \quad \hat{c}_a \quad \hat{d}_a \quad \hat{c}_s \quad \hat{d}_s]^T, \quad (15)$$

$$\mathbf{y} = [\Delta g_s(t_1) \quad \Delta g_s(t_2) \quad \cdots \quad \Delta g_s(t_N)]^T, \quad (16)$$

$$\mathbf{A} = \begin{bmatrix} 1 & t_1 & \cos \frac{2\pi t_1}{T_a} & \sin \frac{2\pi t_1}{T_a} & \cos \frac{2\pi t_1}{T_s} & \sin \frac{2\pi t_1}{T_s} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ 1 & t_N & \cos \frac{2\pi t_N}{T_a} & \sin \frac{2\pi t_N}{T_a} & \cos \frac{2\pi t_N}{T_s} & \sin \frac{2\pi t_N}{T_s} \end{bmatrix}. \quad (17)$$

STL [56] is a non-parametric method of decomposing a time series into a seasonal component $S(t)$, a trend component $T(t)$ and a remainder component $R(t)$, such that:

$$\Delta g_s(t) = S(t) + T(t) + R(t) \quad (18)$$

and $S(t) = \widehat{\Delta g_s}(t)$. STL can be used in a time series with gaps and became a common method of analyzing basin-averaged estimates of GRACE-derived gravity and mass changes. Some examples are given in the recent studies [57] and [58]. Seasonal and trend components are calculated using an iterative procedure based on locally weighted regression (Loess; [59]). We summarize the STL method in the following six steps, using the same notation as in [56] whenever is applicable:

1. The de-trended time series $\Delta g_s - T^{(k)}$ is calculated using the estimated trend from the previous iteration k . A zero trend is used for the first iteration.
2. Based on the period of the seasonal component, subseries are formed and smoothed using Loess. For example, the estimation of the annual component requires the formulation of twelve subseries; the first one containing all January values, the second one all February values, etc.
3. The seasonal time series $C^{(k)}$ is reconstructed from the smoothed subseries of Step 2 and an additional low-pass filtering is applied to reveal any remaining trend. The low-pass filtered time series is denoted as $L^{(k+1)}$.

4. The seasonal component is calculated by detrending the seasonal time series of Step 3, i. e., $S^{(k+1)} = C^{(k)} - L^{(k+1)}$.
5. The deseasoned time series $\Delta g_s - S^{(k+1)}$ is calculated.
6. The trend component $T^{(k+1)}$ is calculated by filtering the deseasoned time series of Step 5 using Loess.

Steps 1–5 are repeated until convergence criteria for $S(t)$ and $T(t)$ are met. The remainder $R(t)$ is then calculated by:

$$R(t) = \Delta g_s(t) - S(t) - T(t). \quad (19)$$

STL has the potential of identifying possible outliers in the data by incorporating robustness weights for each measurement into the Loess filtering. These weights are calculated iteratively by enclosing Steps 1–5 into a second (outer) loop. This is not performed here because it is highly unusual that filtered GRACE and GLDAS data contain outliers. The STL algorithm does not account for the simultaneous estimate of more than one periodic component like LSSA. We first estimate and remove the semi-annual constituent from Δg_s and then used the resulting time series to estimate and remove the annual constituent.

3 Results

The time series of absolute gravity changes, corrected for the gravimeter location and local hydrology effects, is given in Figure 12. Compared with the time series of Figure 5, there is a decrease in the magnitude range of the corrected gravimeter data, going from approximately -10 – $25 \mu\text{Gal}$ to -9 – $10 \mu\text{Gal}$. The corrected gravimeter series mostly represents the non-local hydrology signal.

The GRACE-derived gravity changes, deseasoned using LSSA and STL are provided in Figures 13 and 14, respectively. These time series mainly represent the inter-








Figure 12: Gravimeter-based corrected gravity changes.

Figure 13: GRACE-derived Δg_r using LSSA.Figure 15: GLDAS-derived Δg_r using LSSA.Figure 14: GRACE-derived Δg_r using STL.Figure 16: GLDAS-derived Δg_r using STL.

annual variations of land hydrology. The CSR and JPL series agree quite well, with no clear pattern in the differences between the two solutions. This suggests that the differences between CSR and JPL are due to random errors in the processing strategy of each center. The two methods of removing the seasonality provide comparable results, with STL to produce time series with slightly smaller magnitude. The magnitude reduction using STL can be attributed to the absorption of some signal from the seasonal component $S(t)$ that can vary in amplitude. On the other hand, LSSA provide a seasonal signal with constant amplitude.

The deseasoned time series of gravity changes for all four GLDAS LSMs is provided in Figure 15 for LSSA and in Figure 16 for STL. Although all LSMs follow the same long-term behavior, there are some substantial differences amongst them. These differences are generally attributed to the modeling of GLDAS parameters, i. e., using different number of layers and depths for modeling soil moisture. The Mosaic LSM shows the highest magnitude and strongest deviation from the rest of LSMs, especially from 2002 to 2004. The LSM with the smallest magnitude is CLM. The same conclusions are deduced by interpreting the results of Figure 11. The general disagreement of Mo-

saic and CLM with GRACE and GLDAS products in Europe is also demonstrated by Yang et al. [60]. LSSA and STL produce deseasoned time series in close agreement, as in GRACE case.

3.1 Correlation analysis

We perform a correlation analysis to examine the level of agreement amongst computed time series using the Pearson correlation coefficient. The results are provided in Table 1. The lower triangular part of Table 1 contains the correlation coefficient of detrended GRACE and GLDAS time series using LSSA and the upper triangular part using STL. The lower triangular elements are compared with the corresponding upper triangular elements and the instances that show higher correlation are underlined. This is done to investigate if LSSA or STL systematically produces deseasoned time series with improved correlation. Correlation coefficients are also calculated only for the 2009–2012 period, which includes the effects of the heaviest flood and increased precipitation that took place in Poland. The correlation coefficients for 2009–2012 are given in square brackets.

Table 1: Correlation coefficient.

LSSA	STL							
	GRACE CSR	GRACE JPL	GLDAS CLM	GLDAS Mosaic	GLDAS Noah	GLDAS VIC	FG-5 (original)	FG-5 (corrected)
GRACE CSR		0.88 [0.89]	0.70 [0.77]	0.65 [0.86]	0.78 [0.86]	0.63 [0.77]	0.60 [0.75]	0.66 [0.81]
GRACE JPL	0.89 [0.91]		0.67 [0.76]	0.67 [0.85]	0.75 [0.86]	0.59 [0.76]	0.62 [0.73]	0.69 [0.84]
GLDAS CLM	0.70 [0.81]	0.65 [0.79]		0.58 [0.66]	0.85 [0.92]	0.86 [0.92]	0.55 [0.53]	0.67 [0.78]
GLDAS Mosaic	0.64 [0.86]	0.65 [0.84]	0.57 [0.63]		0.68 [0.78]	0.61 [0.63]	0.87 [0.90]	0.86 [0.82]
GLDAS Noah	0.77 [0.92]	0.75 [0.93]	0.84 [0.90]	0.68 [0.78]		0.90 [0.95]	0.62 [0.65]	0.73 [0.84]
GLDAS VIC	0.64 [0.84]	0.62 [0.84]	0.84 [0.90]	0.62 [0.62]	0.90 [0.94]		0.52 [0.49]	0.64 [0.71]
FG-5 (original)	0.54 [0.71]	0.57 [0.71]	0.53 [0.50]	0.87 [0.90]	0.62 [0.65]	0.51 [0.49]		0.95 [0.85]
FG-5 (corrected)	0.62 [0.83]	0.65 [0.87]	0.65 [0.76]	0.87 [0.84]	0.73 [0.85]	0.64 [0.71]	0.95 [0.85]	

The GRACE data show good agreement with GLDAS data, with a correlation in the range of 0.59–0.78 for the complete period examined. The highest correlation (0.78) is attained when CSR and Noah are compared using STL. The correlation between GRACE and GLDAS is increased to the range of 0.76–0.93 when the 2009–2012 period is examined, with the highest correlation obtained for JPL and Noah data using LSSA. Although LSSA and STL show similar correlation, slightly better results are produced using LSSA. The correlation between different LSMs is at 0.57–0.90 for the complete period and at 0.62–0.92 for 2009–2012. In both cases, VIC and Noah show the best agreement. Improved correlation amongst the LSMs is obtained using STL.

The original gravimeter time series is moderately correlated with both GRACE and GLDAS models. The highest correlation (0.87 for the complete period and 0.90 for 2009–2012) is obtained for GLDAS Mosaic, whereas the correlation with the rest of GLDAS and GRACE models is at 0.50–0.75. STL produces deseasoned GRACE and GLDAS time series that are better correlated with the original gravimeter data. The corrected gravimeter time series shows higher correlation with both GRACE and GLDAS data than the original gravimeter series. Considering GRACE, the correlation is at 0.62–0.69 for the complete period and at 0.81–0.87 for 2009–2012. For GLDAS data, the corresponding ranges are 0.64–0.87 and 0.71–0.85. When examining the complete period, the highest correlation (0.87) is obtained between the corrected gravimeter data and Mosaic using LSSA. For the 2009–2012 period, the same gravimeter data are better correlated (0.87) with the

JPL series using LSSA. The higher correlation of the corrected gravimeter data with the GRACE and GLDAS models indicates that most of the local hydrology signal is probably removed successfully.

3.2 Hydrology and climate signatures

We analyze the results presented in Figures 12–16 to connect anomalies in the gravity changes with extreme hydrological and climate events. Averaged time series of all data sets are given in Figure 17 along with error bars, representing the standard deviation for each measurement (gravimeter data) or the deviation of the ensemble time series (GRACE and GLDAS data). The GRACE average is derived from the four time series given in Figures 13 and 14. The GLDAS average is computed by the CLM, Noah and




Figure 17: Ensemble average of GRACE, GLDAS and gravimeter time series.

VIC LSMs given in Figures 15 and 16. The Mosaic LSM is excluded due to its large deviations and lower correlation with other LSMs. For both GRACE and GLDAS data, the standard deviation varies from 0.1–1.9 μGal depending on the monthly solution. These values are mainly due to random errors and different strategies used by the processing centers (GRACE) and LSMs (GLDAS). For the error budget of the corrected gravimeter time series, only the instrument accuracy is taken into account, which ranges from 1.9 to 2.3 μGal . The accuracy level of the gravimeter series is probably underestimated, meaning that the true standard deviation is higher, because the propagation of errors due to the corrections described in Sections 2.1.2 and 2.1.3 is not taken into account. For example, in areas where the topography significantly affects the modeling of gravity measurements, the assessment of DEM errors is especially important [34]. A detailed discussion on the uncertainties of post-processed gravimeter measurements is also given in Creutzfeldt et al. [61].

Time periods with increased precipitation levels are expected to be followed by an increase in terrestrial water masses and a higher value of gravity. A decrease in the measured gravity is expected due to water depletion during periods of drought. We examine several events documented in the literature that occurred in Poland and central Europe in the period 2002–2016. The averaged time series are then used to find projected signatures of these events. Due to the short time span, the presence of long-time gaps and the reduced accuracy of the gravimeter time series, only a limited number of events can be identified. The events studied are given in the subsections below.

3.2.1 The 2003 severe heat wave

During the summer of 2003, a severe heat wave was reported in central Europe with the mean surface temperature to rise $\sim 3^\circ\text{C}$ above normal levels [62] accompanied by total precipitation levels below average [15]. This heat wave was probably the warmest recorded since 1500 with a return period of more than 5000 years [63], making it extremely unlikely to repeat in the near future. The resulting drought of this heat wave is visible in the GRACE and GLDAS data with a decrease of $2 \pm 0.9 \mu\text{Gal}$ in gravity during August. Using GRACE data, this event is better evident in the JPL time series using STL (Figure 14) with a clear negative peak of $\sim 3 \mu\text{Gal}$ around August–September 2003. Both GRACE and GLDAS time series provide negative gravity changes throughout 2003. Andersen et al. [14] also reports a depletion in GRACE-derived terrestrial

water storage related to the 2003 central European heat wave.

3.2.2 The 2005 increased precipitation

Increased precipitation levels are reported in central Europe from the beginning of 2005 until March [15], accompanied by ample rainfall in central and eastern Europe during July–August [64]. GRACE time series show an increase in gravity change for the most part of 2005, with three distinctive peaks occurring in March, May and August. The highest peak is in May and produces an anomaly of $\sim 2.5 \pm 0.3 \mu\text{Gal}$. Only the May peak is clearly evident in the GLDAS series, producing an anomaly of $\sim 1.5 \pm 0.5 \mu\text{Gal}$. It is also seen from Figures 15 and 16 that Noah LSM produces the highest anomaly ($\sim 3 \mu\text{Gal}$) that is in good agreement with GRACE time series.

3.2.3 The 2010 flooding

The 2010 flood that mostly affected southern Poland was the result of several days of heavy rain and thunderstorm during May–June 2010. Especially on May 16th–17th 2010, a precipitation of up to 200 mm occurred over southern Poland [65]. The aftermath of this event included considerably damaged farmlands, and flooded towns and agricultural areas. The flood also claimed the lives of at least twenty people and resulted the death of many animals. Due to its intensity and extent, this event was categorized as an outstanding heavy precipitation event [66]. The extend of the 2010 flooding is evident in all three data sets. The gravimeter time series show positive anomalies in gravity changes starting from May, with two peaks occurring in September 2010 and January 2011. The magnitude of these anomalies starts from $\sim 6.5 \pm 1.9 \mu\text{Gal}$ in May and reaches a global maximum of $14 \pm 2 \mu\text{Gal}$ around September. The May–June flood event is also seen in GRACE gravity changes, with a positive anomaly in May reaching $3.5 \pm 0.4 \mu\text{Gal}$. The anomaly magnitude drops to $\sim 2 \mu\text{Gal}$ in July and increases again until December, reaching a magnitude of $6 \pm 0.6 \mu\text{Gal}$. GLDAS time series show the same behavior as GRACE, with positive gravity change anomalies in 2010. The effect of May–June flood is evident in June with an average magnitude of $3.5 \pm 1.5 \mu\text{Gal}$, followed by a drop at $1 \mu\text{Gal}$ in July and then increasing until it reaches a magnitude of $5.5 \pm 1.2 \mu\text{Gal}$ in February 2011. Noah LSM produces the highest gravity change anomalies with $5 \mu\text{Gal}$ in June 2010 and $7 \mu\text{Gal}$ in February 2011. A shift on the global maximum

is also noticeable between gravimeter and GRACE/GLDAS data.

3.2.4 The 2011 increased precipitation

After the 2010 flooding, increased precipitation was reported in July 2011 over eastern Poland. The Institute of Meteorology and Water Management of the Polish National Research Institute reported total precipitation levels of up to 340 mm that correspond to an increase of 450 % with respect to the 1971–2000 average precipitation levels. The event is recorded in gravimeter time series as a rapid increase in gravity reaching a value of $-9 \pm 2.1 \mu\text{Gal}$ in July and continued by $9.4 \pm 2.1 \mu\text{Gal}$ in August. The 2011 increased precipitation is also identified in GRACE data with an increase in gravity change starting from July and reaching a peak in August with an anomaly of $4 \pm 0.8 \mu\text{Gal}$. GLDAS time series shows the same behavior as GRACE, with the gravity change anomalies increasing in July, reaching a maximum value of $-4 \pm 1.6 \mu\text{Gal}$ in August and then decreasing until the end of 2011.

3.2.5 The 2013 flooding

An extreme precipitation event was also reported in May–June 2013 that caused a flood in Poland [67]. At the end of this event (June 2013), record precipitation levels were recorder in eastern Europe [68]. Although, the gravimeter time series shows a positive anomaly of $3.7 \pm 2.1 \mu\text{Gal}$ in early May, no direct conclusions can be inferred for the evolution of these events using gravimeter observations due to the absence of data for the latter half of 2013. The May–June extreme precipitation event coincides with the positive gravity change anomalies that peaks at $3 \mu\text{Gal}$ during June 2013 for both GRACE and GLDAS time series.

3.2.6 The 2015 drought

2015 was a notably dry year for central Europe [69]. In the same year, Poland experienced an extremely hot and dry summer, especially during August–September, causing extensive crop yield damages. Low precipitation levels resulted in the lowest discharge values for many rivers, including the Vistula River (~ 9 km from Józefosław) that passes through our study area [70]. In Poland, the 2015 drought was the result of a 3-month extreme summer drought that occurred in August and affected 47 % of the country, and a 12-month drought occurred again in August

and affected 44 % of the country [71]. The signature of the 2015 drought is seen in all three data sets. In the gravimeter time series, a steep drop in the gravity is observed, decreasing from $2 \mu\text{Gal}$ in June to $-2.5 \pm 2 \mu\text{Gal}$ in August and $-2.3 \pm 2.3 \mu\text{Gal}$ in September. The signal-to-noise ratio for the gravimeter measurements in the same period is close or equal to one, making them statistically insignificant for the monitoring of this event. In the GRACE data, there is a negative anomaly throughout 2015. The gravity changes reach their minimum in September with a magnitude of $-5 \pm 1 \mu\text{Gal}$. The averaged GLDAS time series also show negative anomalies in gravity changes during 2015. The local minimum for the same period occurs around July–August with a magnitude of $-2.3 \pm 1.2 \mu\text{Gal}$. The Noah time series deseasoned using STL (Figure 14) shows the highest negative peak at $-4 \mu\text{Gal}$.

4 Conclusions

We examine the gravity changes in central Poland from 2002–2016 using absolute gravimeter measurements, GRACE monthly solutions and GLDAS LSMs. After applying various corrections and removing seasonal signals, we analyze the data to detect geophysical signatures connected to extreme hydrological events. We successfully identify signatures related to heat waves and droughts, as well as increased precipitation and floods in Poland and the proximity of central Europe. The severity and extend of the 2010 flood occurred in central Europe is predominantly noticeable, resulting in gravity change anomalies of 3.5 – $14 \mu\text{Gal}$ depending on the data source. Negative gravity change anomalies of 2.5 – $5 \mu\text{Gal}$ are also identified and connected to reported drought conditions. Our results suggest that methods of gravity field monitoring provide a viable method of identifying extreme events on regional scales. The correlation analysis shows reasonable agreement between gravimeter, GRACE and GLDAS data. The correlation is increased when the corrected gravimeter data are used, indicating that the method of removing the local hydrological influence from the gravimeter measurements is reliable. Increased correlation is also obtained when the analysis is performed only for the 2009–2012 period that includes the 2010 extreme flood and 2011 increased precipitation event. The seasonal signal is removed using LSSA and STL, with both methods to produce comparable results. In most cases, STL produces time series with slightly improved correlation that LSSA.

The monitoring of mass changes is performed in terms of gravity changes. Due to limited availability of in situ

data and reported results from previous studies, our analysis is restricted to a qualitative assessment. When in situ hydrology data are available, the conversion of gravity changes to water mass changes can be done in a straightforward way for GRACE and GLDAS data, allowing a quantitative analysis (i. e., in terms of TWS or EWH). Another limitation of our study is the presence of extended time gaps in the gravimeter measurements, and their reduced accuracy due to instrumental noise level and approximate corrections due to local hydrology. Improved gravimeter data can be obtained only with a superconducting gravimeter and by accurately modeling local hydrogeological interactions using localized information. Further investigation is therefore required for the reliable removal of local hydrology from the absolute gravimeter located in Józefosław. The findings of this study can be extended by analyzing basin-scale averages of various global precipitation models. Such an analysis will potentially increase our confidence for the interpretation of small fluctuations in GRACE TWS estimates. Future studies will also be focused on the optimal combination of gravity changes coming from different sources for enhancing the identification of extreme hydrological events.

Acknowledgment: The two anonymous reviewers are thanked for their valuable comments and suggestions. Dr. Don Chambers and Dr. Jennifer Bonin are thanked for kindly providing geocenter time series consistent with RL06 GRACE data. NASA's PODAAC and GES DISC services are thanked for making freely available the GRACE Level 2 data and the GLDAS models. Figure 1 is produced using the M_Map mapping toolbox [72].

Funding: Financial support for this research was provided to the first author by the National Science Center, Poland, agreement number UMO-2015/17/B/ST10/03927 from 16th March 2016; and to the third author by Natural Sciences and Engineering Research Council of Canada.

References

- [1] A. Eicker, M. Schumacher, J. Kusche, P. Döll, and H. M. Schmied, "Calibration/Data Assimilation Approach for Integrating GRACE Data into the WaterGAP Global Hydrology Model (WGHM) Using an Ensemble Kalman Filter: First Results," *Surv Geophys*, vol. 35, no. 6, pp. 1285–1309, Nov. 2014.
- [2] M. Khaki *et al.*, "Assessing sequential data assimilation techniques for integrating GRACE data into a hydrological model," *Advances in Water Resources*, vol. 107, pp. 301–316, Sep. 2017.
- [3] M. Khaki, I. Hoteit, M. Kuhn, E. Forootan, and J. Awange, "Assessing data assimilation frameworks for using multi-mission satellite products in a hydrological context," *Science of The Total Environment*, vol. 647, pp. 1031–1043, Jan. 2019.
- [4] B. D. Tapley, S. Bettadpur, M. Watkins, and C. Reigber, "The gravity recovery and climate experiment: Mission overview and early results," *Geophys. Res. Lett.*, vol. 31, no. 9, p. L09607, May 2004.
- [5] M. Rodell, I. Velicogna, and J. S. Famiglietti, "Satellite-based estimates of groundwater depletion in India," *Nature*, vol. 460, no. 7258, pp. 999–1002, Aug. 2009.
- [6] V. M. Tiwari, J. Wahr, and S. Swenson, "Dwindling groundwater resources in northern India, from satellite gravity observations," *Geophys. Res. Lett.*, vol. 36, no. 18, p. L18401, Sep. 2009.
- [7] W. Feng, M. Zhong, J.-M. Lemoine, R. Biancale, H.-T. Hsu, and J. Xia, "Evaluation of groundwater depletion in North China using the Gravity Recovery and Climate Experiment (GRACE) data and ground-based measurements," *Water Resources Research*, vol. 49, no. 4, pp. 2110–2118, Apr. 2013.
- [8] J. Tang, H. Cheng, and L. Liu, "Assessing the recent droughts in Southwestern China using satellite gravimetry," *Water Resour. Res.*, vol. 50, no. 4, pp. 3030–3038, Apr. 2014.
- [9] K. A. Voss, J. S. Famiglietti, M. Lo, C. de Linage, M. Rodell, and S. C. Swenson, "Groundwater depletion in the Middle East from GRACE with implications for transboundary water management in the Tigris-Euphrates-Western Iran region," *Water Resour. Res.*, vol. 49, no. 2, pp. 904–914, Feb. 2013.
- [10] G. Joodaki, J. Wahr, and S. Swenson, "Estimating the human contribution to groundwater depletion in the Middle East, from GRACE data, land surface models, and well observations," *Water Resour. Res.*, vol. 50, no. 3, pp. 2679–2692, Mar. 2014.
- [11] J. S. Famiglietti *et al.*, "Satellites measure recent rates of groundwater depletion in California's Central Valley," *Geophys. Res. Lett.*, vol. 38, no. 3, p. L03403, Feb. 2011.
- [12] B. R. Scanlon *et al.*, "Groundwater depletion and sustainability of irrigation in the US High Plains and Central Valley," *PNAS*, vol. 109, no. 24, pp. 9320–9325, Jun. 2012.
- [13] B. R. Scanlon, L. Longuevergne, and D. Long, "Ground referencing GRACE satellite estimates of groundwater storage changes in the California Central Valley, USA," *Water Resources Research*, vol. 48, no. 4, Apr. 2012.
- [14] O. B. Andersen, S. I. Seneviratne, J. Hinderer, and P. Viterbo, "GRACE-derived terrestrial water storage depletion associated with the 2003 European heat wave," *Geophysical Research Letters*, vol. 32, no. 18, Sep. 2005.
- [15] F. Seitz, M. Schmidt, and C. K. Shum, "Signals of extreme weather conditions in Central Europe in GRACE 4-D hydrological mass variations," *Earth Planet. Sci. Lett.*, vol. 268, no. 1, pp. 165–170, Apr. 2008.
- [16] J. L. Chen, C. R. Wilson, and B. D. Tapley, "The 2009 exceptional Amazon flood and interannual terrestrial water storage change observed by GRACE," *Water Resources Research*, vol. 46, no. 12, Dec. 2010.
- [17] B. D. Vishwakarma, K. Jain, N. Sneeuw, and B. Devaraju, "Mumbai 2005, Bihar 2008 Flood Reflected in Mass Changes Seen by GRACE Satellites," *J Indian Soc Remote Sens*, vol. 41, no. 3, pp. 687–695, Sep. 2013.

- [18] B. T. Gouweleeuw *et al.*, “Daily GRACE gravity field solutions track major flood events in the Ganges–Brahmaputra Delta,” *Hydrology and Earth System Sciences*, vol. 22, no. 5, pp. 2867–2880, May 2018.
- [19] M. Rodell *et al.*, “The Global Land Data Assimilation System,” *Bull. Amer. Meteor. Soc.*, vol. 85, no. 3, pp. 381–394, Mar. 2004.
- [20] T. H. Syed, J. S. Famiglietti, M. Rodell, J. Chen, and C. R. Wilson, “Analysis of terrestrial water storage changes from GRACE and GLDAS,” *Water Resour. Res.*, vol. 44, no. 2, p. W02433, Feb. 2008.
- [21] S. Werth, A. Güntner, R. Schmidt, and J. Kusche, “Evaluation of GRACE filter tools from a hydrological perspective,” *Geophysical Journal International*, vol. 179, no. 3, pp. 1499–1515, Dec. 2009.
- [22] E. Rangelova, M. G. Sideris, and J. W. Kim, “On the capabilities of the multi-channel singular spectrum method for extracting the main periodic and non-periodic variability from weekly GRACE data,” *Journal of Geodynamics*, vol. 54, pp. 64–78, Mar. 2012.
- [23] J. Huang, G. Pavlic, A. Rivera, D. Palombi, and B. Smerdon, “Mapping groundwater storage variations with GRACE: a case study in Alberta, Canada,” *Hydrogeol J*, vol. 24, no. 7, pp. 1663–1680, Nov. 2016.
- [24] Z. Rzepecka, M. Birylo, J. Kuczynska-Sieghien, J. Nastula, and P. Katarzyna, “Analysis of groundwater level variations and water balance in the area of the Sudety mountains,” *Acta Geodynamica et Geomaterialia*, vol. 14, no. 187, pp. 307–315, May 2017.
- [25] A. Brzeziński *et al.*, “Geodetic and Geodynamic Studies at Department of Geodesy and Geodetic Astronomy Wut,” *Reports on Geodesy and Geoinformatics*, vol. 100, no. 1, pp. 165–200, Jun. 2016.
- [26] J. Neumeyer *et al.*, “Combination of temporal gravity variations resulting from superconducting gravimeter (SG) recordings, GRACE satellite observations and global hydrology models,” *J Geodesy*, vol. 79, no. 10–11, pp. 573–585, Feb. 2006.
- [27] J. Neumeyer *et al.*, “Analysis of gravity field variations derived from Superconducting Gravimeter recordings, the GRACE satellite and hydrological models at selected European sites,” *Earth Planet Sp*, vol. 60, no. 5, pp. 505–518, May 2008.
- [28] D. Crossley, C. de Linage, J. Hinderer, J.-P. Boy, and J. Famiglietti, “A comparison of the gravity field over Central Europe from superconducting gravimeters, GRACE and global hydrological models, using EOF analysis,” *Geophys J Int*, vol. 189, no. 2, pp. 877–897, May 2012.
- [29] M. Abe *et al.*, “A comparison of GRACE-derived temporal gravity variations with observations of six European superconducting gravimeters,” *Geophys J Int*, vol. 191, no. 2, pp. 545–556, Nov. 2012.
- [30] J. B. Rogowski *et al.*, “Activities of Józefosław Astro-Geodetic Observatory in the last five decades,” *Reports on Geodesy*, vol. 2/89, pp. 31–52, 2010.
- [31] S. Deville, T. Jacob, J. Chéry, and C. Champollion, “On the impact of topography and building mask on time varying gravity due to local hydrology,” *Geophys J Int*, vol. 192, no. 1, pp. 82–93, Jan. 2013.
- [32] B. Creutzfeldt, A. Güntner, H. Wziontek, and B. Merz, “Reducing local hydrology from high-precision gravity measurements: a lysimeter-based approach,” *Geophys J Int*, vol. 183, no. 1, pp. 178–187, Oct. 2010.
- [33] M. Reich, M. Mikolaj, T. Blume, and A. Güntner, “Reducing gravity data for the influence of water storage variations beneath observatory buildings,” *Geophysics*, vol. 84, no. 1, pp. EN15–EN31, Oct. 2018.
- [34] B. Creutzfeldt, A. Güntner, T. Klügel, and H. Wziontek, “Simulating the influence of water storage changes on the superconducting gravimeter of the Geodetic Observatory Wettzell,” *Geophysics*, vol. 73, no. 6, pp. WA95–WA104, Nov. 2008.
- [35] D. Nagy, G. Papp, and J. Benedek, “The gravitational potential and its derivatives for the prism,” *Journal of Geodesy*, vol. 74, no. 7–8, pp. 552–560, 2000.
- [36] D. Nagy, G. Papp, and J. Benedek, “Corrections to ‘The gravitational potential and its derivatives for the prism’,” *Journal of Geodesy*, vol. 76, no. 8, pp. 475–475, Nov. 2002.
- [37] H.-G. Wenzel, “The Nanogal software: earth tide data processing package ETERNA 3.30,” *Bull. Inf. Marees Terrestres*, no. 124, pp. 9425–9439, 1996.
- [38] Y. Tamura, “A harmonic development of the tide-generating potential,” *Bull. Inf. Marees Terrestres*, no. 124, pp. 9425–9439, 1987.
- [39] F. Lyard, F. Lefevre, T. Letellier, and O. Francis, “Modelling the global ocean tides: modern insights from FES2004,” *Ocean Dynamics*, vol. 56, no. 5, pp. 394–415, Dec. 2006.
- [40] J.-P. Boy and F. Lyard, “High-frequency non-tidal ocean loading effects on surface gravity measurements,” *Geophys J Int*, vol. 175, no. 1, pp. 35–45, Oct. 2008.
- [41] S. Rosat *et al.*, “A two-year analysis of the iOSG-24 superconducting gravimeter at the low noise underground laboratory (LSBB URL) of Rustrel, France: Environmental noise estimate,” *Journal of Geodynamics*, vol. 119, pp. 1–8, Sep. 2018.
- [42] C. R. Wilson, B. Scanlon, J. Sharp, L. Longuevergne, and H. Wu, “Field test of the superconducting gravimeter as a hydrologic sensor,” *Ground Water*, vol. 50, no. 3, pp. 442–449, Jun. 2012.
- [43] S. Swenson, D. Chambers, and J. Wahr, “Estimating geocenter variations from a combination of GRACE and ocean model output,” *J. Geophys. Res.*, vol. 113, no. B8, p. B08410, Aug. 2008.
- [44] M. Cheng, B. D. Tapley, and J. C. Ries, “Deceleration in the Earth’s oblateness,” *J. Geophys. Res. Solid Earth*, vol. 118, no. 2, pp. 740–747, Feb. 2013.
- [45] J. Wahr, R. S. Nerem, and S. V. Bettadpur, “The pole tide and its effect on GRACE time-variable gravity measurements: Implications for estimates of surface mass variations,” *J. Geophys. Res. Solid Earth*, vol. 120, no. 6, p. 2015JB011986, Jun. 2015.
- [46] J. Ries *et al.*, “The Combined Gravity Model GGM05C.” GFZ Data Services, 2016.
- [47] S. Swenson and J. Wahr, “Post-processing removal of correlated errors in GRACE data,” *Geophys. Res. Lett.*, vol. 33, no. 8, p. L08402, Apr. 2006.
- [48] D. Piretzidis, G. Sra, G. Karantaidis, M. G. Sideris, and H. Kabirzadeh, “Identifying presence of correlated errors using machine learning algorithms for the selective de-correlation of GRACE harmonic coefficients,” *Geophys J Int*, vol. 215, no. 1, pp. 375–388, Oct. 2018.

- [49] D. Piretzidis and M. G. Sideris, "SHADE: A MATLAB toolbox and graphical user interface for the empirical de-correlation of GRACE monthly solutions," *Computers & Geosciences*, vol. 119, pp. 137–150, Oct. 2018.
- [50] C. Jekeli, *Alternative methods to smooth the Earth's gravity field*. Columbus, Ohio: Ohio State University Dept. of Geodetic Science and Surveying, 1981.
- [51] H. Wang et al., "Load Love numbers and Green's functions for elastic Earth models PREM, iasp91, ak135, and modified models with refined crustal structure from Crust 2.0," *Computers & Geosciences*, vol. 49, no. Supplement C, pp. 190–199, Dec. 2012.
- [52] F. W. Landerer and S. C. Swenson, "Accuracy of scaled GRACE terrestrial water storage estimates," *Water Resour. Res.*, vol. 48, no. 4, p. W04531, Apr. 2012.
- [53] J. Wahr, M. Molenaar, and F. Bryan, "Time variability of the Earth's gravity field: Hydrological and oceanic effects and their possible detection using GRACE," *J. Geophys. Res.*, vol. 103, no. B12, pp. 30205–30229, Dec. 1998.
- [54] P. Vaníček, "Further development and properties of the spectral analysis by least-squares," *Astrophys Space Sci*, vol. 12, no. 1, pp. 10–33, Jul. 1971.
- [55] P. Vaníček, "Approximate spectral analysis by least-squares fit," *Astrophys Space Sci*, vol. 4, no. 4, pp. 387–391, Aug. 1969.
- [56] R. B. Cleveland, W. S. Cleveland, J. E. McRae, and I. Terpenning, "STL: A Seasonal-Trend Decomposition Procedure Based on Loess," *Journal of Official Statistics*, vol. 6, no. 1, pp. 3–73, 1990.
- [57] V. Humphrey, L. Gudmundsson, and S. I. Seneviratne, "Assessing Global Water Storage Variability from GRACE: Trends, Seasonal Cycle, Subseasonal Anomalies and Extremes," *Surv Geophys*, vol. 37, no. 2, pp. 357–395, Mar. 2016.
- [58] B. R. Scanlon et al., "Global models underestimate large decadal declining and rising water storage trends relative to GRACE satellite data," *PNAS*, p. 201704665, Jan. 2018.
- [59] W. S. Cleveland, "Robust Locally Weighted Regression and Smoothing Scatterplots," *Journal of the American Statistical Association*, vol. 74, no. 368, pp. 829–836, Dec. 1979.
- [60] T. Yang, C. Wang, Z. Yu, and F. Xu, "Characterization of spatio-temporal patterns for various GRACE- and GLDAS-born estimates for changes of global terrestrial water storage," *Global and Planetary Change*, vol. 109, pp. 30–37, Oct. 2013.
- [61] B. Creutzfeldt, A. Güntner, H. Thoss, B. Merz, and H. Wziontek, "Measuring the effect of local water storage changes on in situ gravity observations: Case study of the Geodetic Observatory Wettzell, Germany," *Water Resources Research*, vol. 46, no. 8, Aug. 2010.
- [62] C. Schär et al., "The role of increasing temperature variability in European summer heatwaves," *Nature*, vol. 427, no. 6972, pp. 332–336, Jan. 2004.
- [63] J. Luterbacher, D. Dietrich, E. Xoplaki, M. Grosjean, and H. Wanner, "European Seasonal and Annual Temperature Variability, Trends, and Extremes Since 1500," *Science*, vol. 303, no. 5663, pp. 1499–1503, Mar. 2004.
- [64] NOAA-NCEI, "NOAA National Centers for Environmental Information, State of the Climate: Global Climate Report for Annual 2005," 2006. [Online]. Available: <https://www.ncdc.noaa.gov/sotc/global/200513>. [Accessed: 26-Nov-2018].
- [65] NOAA-NCEI, "NOAA National Centers for Environmental Information, State of the Climate: Global Hazards for May 2010," 2010. [Online]. Available: <https://www.ncdc.noaa.gov/sotc/hazards/201005>. [Accessed: 26-Nov-2018].
- [66] P. Bissolli, K. Friedrich, J. Rapp, and M. Ziese, "Flooding in eastern central Europe in May 2010 – reasons, evolution and climatological assessment," *Weather*, vol. 66, no. 6, pp. 147–153, Jun. 2011.
- [67] NOAA-NCEI, "NOAA National Centers for Environmental Information, State of the Climate: Global Climate Report for Annual 2013," 2014. [Online]. Available: <https://www.ncdc.noaa.gov/sotc/global/201313>. [Accessed: 26-Nov-2018].
- [68] NOAA-NCEI, "NOAA National Centers for Environmental Information, State of the Climate: Global Climate Report for June 2013," 2013. [Online]. Available: <https://www.ncdc.noaa.gov/sotc/global/201306>. [Accessed: 26-Nov-2018].
- [69] NOAA-NCEI, "NOAA National Centers for Environmental Information, State of the Climate: Global Climate Report for Annual 2015," 2016. [Online]. Available: <https://www.ncdc.noaa.gov/sotc/global/201513>. [Accessed: 26-Nov-2018].
- [70] I. Pińskwar, A. Choryński, D. Graczyk, and Z. W. Kundzewicz, "Observed changes in extreme precipitation in Poland: 1991–2015 versus 1961–1990," *Theor Appl Climatol*, Jan. 2018.
- [71] U. Somorowska, "Changes in Drought Conditions in Poland over the Past 60 Years Evaluated by the Standardized Precipitation-Evapotranspiration Index," *Acta Geophys.*, vol. 64, no. 6, pp. 2530–2549, Dec. 2016.
- [72] R. Pawłowicz, *M_Map: A mapping package for MATLAB*. 2018.

ACCURACY ANALYSIS OF GRAVITY FIELD CHANGES FROM GRACE RL06 AND RL05 DATA COMPARED TO IN SITU GRAVIMETRIC MEASUREMENTS IN THE CONTEXT OF CHOOSING OPTIMAL FILTERING TYPE

Viktor SZABÓ¹, Dorota MARJAŃSKA¹

¹ Faculty of Geodesy and Cartography, Warsaw University of Technology,
Warsaw, Poland

e-mails: viktor.szabo@pw.edu.pl, dorota.marjanska@pw.edu.pl

ABSTRACT. Global satellite gravity measurements provide unique information regarding gravity field distribution and its variability on the Earth. The main cause of gravity changes is the mass transportation within the Earth, appearing as, e.g. dynamic fluctuations in hydrology, glaciology, oceanology, meteorology and the lithosphere. This phenomenon has become more comprehensible thanks to the dedicated gravimetric missions such as Gravity Recovery and Climate Experiment (GRACE), Challenging Minisatellite Payload (CHAMP) and Gravity Field and Steady-State Ocean Circulation Explorer (GOCE). From among these missions, GRACE seems to be the most dominating source of gravity data, sharing a unique set of observations from over 15 years. The results of this experiment are often of interest to geodesists and geophysicists due to its high compatibility with the other methods of gravity measurements, especially absolute gravimetry. Direct validation of gravity field solutions is crucial as it can provide conclusions concerning forecasts of subsurface water changes. The aim of this work is to present the issue of selection of filtration parameters for monthly gravity field solutions in RL06 and RL05 releases and then to compare them to a time series of absolute gravimetric data conducted in quasi-monthly measurements in Astro-Geodetic Observatory in Józefosław (Poland). The other purpose of this study is to estimate the accuracy of GRACE temporal solutions in comparison with absolute terrestrial gravimetry data and making an attempt to indicate the significance of differences between solutions using various types of filtration (DDK, Gaussian) from selected research centres.

Keywords: GRACE, DDK, Gaussian filter, FG5

1. INTRODUCTION

The twin GRACE satellites, launched in 2002, had taken detailed measurements of the Earth's gravitational field changes for 15 years. This has revolutionised research on land water resources, glaciology, earthquakes and deformation of Earth's crust. The benefits of continuous observation of our planet through GRACE satellites have led to rerun the project, this time named GRACE Follow-On (GRACE-FO), which was initiated in 2018.

In order to present the distribution of the Earth's gravitational field, the most common representation is to expand gravitational potential function in series of spherical harmonics



functions. Gravity potential V in any point on the surface of the Earth can be described as a function of spherical coordinates $\theta = 90 - \varphi, \lambda$:

$$V(r, \theta, \lambda) = \frac{GM}{R} \sum_{n=0}^{n_{max}} \left(\frac{a}{r}\right)^{n+1} \sum_{m=0}^n (\bar{C}_{nm} \cdot \cos m\lambda + \bar{S}_{nm} \cdot \sin m\lambda) \cdot \bar{P}_{nm}(\cos\theta) \quad (1)$$

where φ is a geodetic latitude, (θ, λ) are the spherical coordinates of this point, r stands for radius vector, GM is the geocentric gravitational constant, a is the semi-major axis of reference ellipsoid defined in International Earth Rotation and Reference Systems Service Convention (IERS2010), $\bar{C}_{nm}, \bar{S}_{nm}$ are the normalised harmonic coefficients of the gravity potential expansion (Stokes' coefficients) and $\bar{P}_{nm}(\cos\theta)$ are the Legendre polynomials of n -th degree and m -th order (Wahr, 1998). To ensure a consistent long-term time series of the gravitational field of the highest possible quality, the values of geopotential coefficients are reprocessed by major scientific centres, the latest solution known as RL06 has replaced the predecessor RL05a. As compared to the previous version, the following components have been changed in RL06: ocean tides models, time-variable a priori gravity field, non-tidal atmospheric and oceanic mass variations (Atmosphere and Ocean De-aliasing Product [AOD1B]), as well as a strategy of data processing described in Dahle et al. (2019). Before interpreting the variability of the field of gravity from GRACE data, it is necessary to reduce the effects of the specific inclination of the orbit of GRACE satellites (that is equal to 89.5°). It usually occurs as characteristic meridional 'stripes' when visualising spatial distribution. There are several methods to dispose this issue in the form of spatial signal filtering. Unfortunately, throughout this process, it is possible to miss some information about the geodynamic signal. To choose an optimal filter, a common method is the comparison of filtered data with terrestrial results from gravimetric and geodetic measurements (e.g. SG, AG).

In Poland, such research was conducted in, e.g. Kuczynska-Sieghien et al. (2019), whereby decomposing the signal with periodic functions, GRACE data was compared with hydrological and gravimetric in situ data. In Godah and Krynski (2017), principal component analysis (PCA) method was used to decompose the periodic signal and then to compare the RL05 data to changes in normal and orthometric heights on the territory of Poland. The article Godah et al. (2018) presents a comparison of satellite-only global geopotential models (GGMs) with quasigeoid undulation derived from levelling and Global Navigation Satellite Systems (GNSS) measurements. The article Godah et al. (2015) presents a comparison of non-isotropic decorrelation filters (denoted by DDK) and Gauss filtration for the Vistula and Odra river basins based on data from the RL05 solution. In a comparison of RL04 data with Global Land Data Assimilation System (GLDAS) time series, described in Kloch-Glowka et al. (2012), DDK1 filter turned out to be the most effective in the noise from observations. Further research on GRACE data compared with gravimetric measurements in Eastern and Central Europe has been outlined in Crossley et al. (2012), Neumeyer et al. (2005) and Abe et al. (2012).

This paper will assess how compatible are terrestrial measurements with satellite signals in the context of filtering GRACE data. The research is based on entire GRACE time series and the last two absolute gravity measurement campaigns performed in the Astro-Geodetic Observatory located in Józefosław (AGO JOZE).

2. GRACE SIGNAL FILTRATION

2.1. Applied algorithms

The source of meridional (North–South oriented) stripes is geometry of the twin-satellites system. They moved in at an altitude of approx. 450 km, separated by 220 km along their orbit track. GRACE consisted of only one pair of satellites at near-polar orbit. The creators' intention

was to provide monthly solutions of GRACE results. The number of observations made on average over 30 days is limited. Hence, there are areas without any numerical information in a month. To succeed in delivering a global solution for every period, an interpolation of the data is necessary.




Figure 1. (a–c) GRACE ground track simulation. Source: own study

However, it causes highly correlated errors in spherical harmonic coefficients due to their orthogonality that appears in Level-1 solutions. In order to reduce this kind of observational noise, spatial smoothing by Gaussian function is used (Jekeli, 1981). Swenson and Wahr (2006) had observed a unique property of spherical harmonic coefficients associated with their decomposition. They also had designed a set of filters to eliminate the problem. Nevertheless, the provided method is not perfect. Due to the orbit inclination of 89.5° , there is a significant accumulation of data in the polar region, while in the equatorial area its spatial resolution is lower (as shown in Figure 1). Gauss filtration smooths the data equally in every direction.

Hence, other solutions are proposed, e.g. filtering with latitude-dependent filters. A decorrelation of monthly global solutions was suggested by J. Kusche. It is based on a priori assumptions of error budget and was tested using hydrological models (Kusche et al., 2009). A similar solution has been presented in Horvath et al. (2018) using full covariance matrix determined in two ways: stochastic and deterministic. Anisotropic DDK filters proved to be a satisfying method that preserves geophysical details from GRACE level 2 products the best (Chen et al., 2006; Kusche, 2007). DDK1-8 filters have become the primary tool used in GRACE data processing over time. Another proposed method is a reduction of the correlation between spherical harmonic coefficients and errors using quadratic polynomials (with a moving window) to fit the resulting function between original and decorrelated C_{nm} coefficients (Duan, 2009). Empirical decorrelation of coefficients is a wide group of methods and will not be analysed in this paper. Despite the large number of filtering approaches, none is stated as universal. This is because the quality of the final solution depends on the latitudes of an examined area and the power of a chosen filter.

2.2. Gaussian filter

Gauss filtration is based on the regular smoothing of variance of the observed gravity field changes by the following kernel function:

$$F(\cos\psi) = \frac{2b}{1-e^{-2b}} e^{-b(1-\cos\psi)} \quad (2)$$

where ψ stands for a spherical distance from the given point and b is calculated by the formula:

$$b = \frac{\ln(2)}{1 - \cos\left(\frac{d}{R}\right)} \quad (3)$$

with d meaning a radius value and R is the equatorial radius, both expressed in kilometres. The filtration process is based on multiplying all spherical harmonic coefficients by a predefined filtration factor. Because the filtering domain depends on the spatial resolution of the data, it is possible to express the Gauss weighting coefficients as:

$$F(\cos\psi) = w_n \quad (4)$$

where w_n value defines the dependence on n -th degree of spherical harmonic function as follows:

$$w_n = \frac{2n-1}{b} w_{n-1} + w_{n-2} \quad (5)$$

These weighting coefficients must be included in the function describing the Earth's gravity field (expanding equation (1)):

$$V(r, \theta, \lambda) = \frac{GM}{R} \sum_{n=0}^{n_{max}} \left(\frac{a}{r}\right)^n w_n \sum_{m=0}^n (\bar{C}_{nm} \cdot \cos m\lambda + \bar{S}_{nm} \cdot \sin m\lambda) \cdot \bar{P}_{nm}(\cos\theta) \quad (6)$$

The size of the radius is crucial. The larger it is, the more it blurs geophysical information contained in coefficients of higher degree, as shown in Figure 2.




Figure 2. Gauss filter spectral scale of factor w_n . Source: own study

According to the Center for Space Research (CSR) standards for processing GRACE Level-2 RL05 and RL06 data (Savannah et al., 2019), different radii are chosen for sea/ocean and land areas, equal to 500 and 300 km, respectively. Examples of applying Gauss filter with various radii are presented in Figure 3a–d.




Figure 3. (a–d) Geoid height changes in metres compiled for GRACE data from the 2002.123 to 2002.137 period published by CSR RL06. Development in relation to the GOCO05S static model with a degree of development of $n = 90$, unfiltered, blurred by a Gaussian filter with 100, 200, 300 km radii. Source: own study

Apparently, Gauss filtration is not an ideal solution to the meridional stripes issue. Due to the frequent passage of satellites around the pole, this region is better covered with data than the equatorial zone. It should be considered if there is a method including the different distance ranges between the stripes at a given latitude.

2.3. Anisotropic DDK filters

The anisotropic filtration method differs from Gaussian filters in that it uses approximate coefficient errors, a full matrix of covariance errors and normalised values of spherical harmonics. A kernel function determines the way of eliminating errors resulting from the orbit path by azimuth-weighted coefficients: narrower in the N–S direction and wider in the E–W direction. The spectrum of a given filter was created as a result of empirical mathematical modelling of error covariance matrix and the methods for developing observations from level 1 to 2 based on distance measurements between GRACE satellites using a K-band inter-satellite sensor. The entire method is described in Kusche (2007). Examples of kernel functions for selected geodetic coordinates in the N–S direction are presented in Figure 4a–c.




Figure 4. (a–c) Examples of DDK base filtration function depending on latitude. Source: own study

For a better understanding of the problem, the maps presented in Figure 5a–h show an application for subsequent types of DDK filtration – geoid undulation changes for a declared period.




Figure 5. (a–h) Geoid height changes in metres compiled for GRACE data from the 2002.123 to 2002.137 period published by CSR RL06. Development in relation to the GOCO05S static model with a degree of development of $n = 90$, filtered by non-isotropic DDK1-8 filters. Source: own study

The full difference between the filtration types used is shown in Figure 6 in terms of the *square root of degree variance of spherical harmonics* depending on their degree. It is well noticeable that the variance of data filtered by Gaussian method with 100 km radius practically coincides with the variance of unfiltered coefficients. In turn, Gaussian filter with a radius of 600 km

ceases to be useful for monthly solutions above 75–77 degree of harmonic function. DDK1-5 filters are on a similar level as Gaussian filter with a radius $R = 300$ km (recommended by the CSR).




Figure 6. (a–f) Square root of Degree Variance of Spherical harmonic from period 2002.123-2002.137 for RL05, RL06 and difference between RL06-RL05. Source: own study

On comparing the Gauss filter to DDK, it can be seen that DDK shows better stability for higher degree/order of spherical harmonic coefficients. Regarding the differences between the RL06 and RL05 versions, slight discrepancies can be noticed, up to 60 harmonic degree. Better compatibility between RL06 and RL05 is preserved by Gaussian filters with radii 500 and 600

km, while in the case of anisotropic filters, DDK 1–4 types show compatibility. All examples discussed above present only one epoch of GRACE mission solutions. Results may vary over time. Presenting the differences between official centres from different epochs over the 15 years may be complicated. One of the possibilities has been presented in Sakumura et al. (2014). It has revealed a clear similarity between the CSR and GeoForschungsZentrum, German Research Centre for Geosciences (GFZ) solutions. Also, a significant difference between the CSR and the GFZ solutions compared to Jet Propulsion Laboratory (JPL) is observed in the basins of Amazon and Congo rivers. In both cases, there is a slight discrepancy in the equivalent water height (EWH) in the polar regions, where it reaches about ± 2 mm/year. In the ocean, the differences are minor and the mean squared error of EWH varies from 12 to 16 mm/year. It is worth mentioning that terrestrial and oceanic areas are developed separately. Solutions for oceans are comparable for each processing centre. Moreover, each of them suggests a comparable radius of filtration as the most effective for these areas. Thus, GRACE results on continents are crucial in comparing the computing strategies of individual data centres. The next section presents an example of local comparison of different GRACE data filtration types derived from three official processing centres.

3. SELECTING AN APPROPRIATE FILTERING TYPE FOR AGO JOZE LOCATION

3.1. Data processing

This part presents a comprehensive comparison of the gravity fluctuations determined from GRACE periodic models and absolute gravimetric measurements at the AGO JOZE. The main goal of the study is to estimate the accuracy of GRACE temporal solutions in comparison with terrestrial gravimetry data. Furthermore, the authors attempted to evaluate the discrepancies between various solutions that were based on numerous DDK and Gauss filters and that were computed in different research centres. A simplified scheme of this experiment is presented in Figure 7.




Figure 7. Scheme of the experiment. Source: own study

Time series analysis was carried out for selected monthly solutions of GRACE missions produced by GFZ, CSR, and JPL. RL06 data (Dahle et al., 2013) from April 2002 to March

2016 was used in the maximum degree/order of expansion equal to 96 and for RL05a data, the values are CSR – d/o 96, GFZ – 90 and JPL – 90, respectively (for certain solutions up to 60). It results in a spatial resolution of about 330 km. This value may vary depending on the selected version and the method of smoothing the signal. GRACE is effective for the study of phenomena in the continental scale. For examined areas smaller than 100,000 km², the signal-to-noise ratio may be weak. Thus, the resulting errors (especially those from smoothing and signal leakage) require user's attention. Despite averaging observations from GRACE, appropriate post-processing methods can preserve geophysical information for areas of about 10,000 km² (Vishwakarma and Devaraju, 2018).




Figure 8. Location of the case study. Source: own study

The gravimetric JOZE station (general location in Figure 8) is in the basement of AGO building, i.e. 5.7 m below the ground, on a 2 × 2 m concrete pole. Absolute measurements were conducted in roughly monthly routine from May 2005 to November 2016 using the FG-5 gravimeter No. 230. This is the longest and homogeneous (considering both accuracy and spatial resolution) time series of gravity values in Poland. The total uncertainty in determining the gravity field force is $\pm 2 \mu\text{Gal}$. Results from the absolute measurements are corrected for the effects related to Earth tides (Wenzel model) and oceanic tides (FES2004 model), changes in atmospheric pressure and polar motion. In addition, gravity values are corrected by the results of international comparison campaigns. Metrological factors (resulting from clock and laser frequency changes) are also considered.

Results measured by an absolute gravimeter are not only affected by systematic geodynamic factors removed during data processing, but also by local hydrological influence. In AGO JOZE, parallel to the gravity data measurements, groundwater level was recorded by a piezometer. After calculating the impact of local subsurface water masses, it was possible to compare terrestrial data with satellite ones. To obtain the desired results, the approach presented in Kuczynska-Siehiem et al. (2019) was used. Piezometric measurements of groundwater level

fluctuations made it possible to estimate the hydrological effect on gravity according to the formula (Creutzfeldt, 2010):

$$\Delta g_{hyd} = 41.92 \cdot Sy \cdot \Delta h \quad (7)$$

Sy (specific yield) means the water content in the pores of a given aquifer and Δh is the change in groundwater level obtained from piezometer readings. In this case, $Sy = 0.13$ was determined on the basis of simple regression of piezometric and gravimetric observations.




Figure 9. Graph of observed dg changes by absolute gravimeter before and after hydro correction against the background of changes in groundwater level. Source: own study

On analysing the graph in Figure 9, it is noticeable that gravimetric measurements are highly dependent on groundwater level fluctuations. The Δg_{hyd} correction reduced the amplitude of the observed g values from 25 to 14 μGal . Compared to the total uncertainty of absolute measurement at $\pm 2 \mu\text{Gal}$, it is clearly seen how sensitive equipment is to changes in local mass distribution.

Data from the GRACE mission was collected as spherical harmonics (.gfc file from the International Center for Global Earth Models [ICGEM] website) in RL06 and RL05a releases. The changes denoted as ΔC_{nm} and ΔS_{nm} were calculated by removing the static part of the gravity field using GGM05C model (Ries et al., 2016) for each monthly solution. According to the valid conventions (technical notes TN-11 and TN-07), GRACE coefficients C_{10} , C_{11} , S_{11} denoting the centre of mass and C_{20} denoting the gravimetric flattening of the Earth (Swenson et al., 2008) have been replaced with the coefficients determined using satellite laser ranging (SLR) measurements (Cheng et al., 2013). Additionally, due to problems with the GRACE-B accelerometer, a significantly higher variance of the C_{30} coefficient could have been observed in the last 7 months of the mission, therefore it was also substituted by a corresponding value from SLR. For the RL06 data, a linear model of polar motion has been introduced, which is consistent with the IERS2010 convention. Hence, it is not recommended to introduce any corrections to the C_{21} and S_{21} coefficients (according to Dahle et al., 2019).

GRACE and FG5 observations were recorded for different epochs. To be able to compare them, it was necessary to interpolate the data. The choice of interpolation method was important because of possible overestimation with a too aggressive approach. Several popular ways were tested in this study and the best one turned out to be a moving average with a window size of 5

months. This allowed to faithfully reflect the original signal without excessive smoothing and the appearance of gross errors.

The comparison of gravity field changes data determined by GRACE sensors and absolute measurements with the FG5 gravimeter was based on gravimetric disturbances. The gravity disturbance is understood here as the difference between the real and normal (referred to ellipsoid) acceleration of gravity on the physical surface of the Earth. It was determined from GRACE data, taking into account the elastic deformation of the Earth as a result of loading (Crossley et al., 2012) according to the following formula:

$$\delta g(\theta, \lambda) = \frac{GM}{R^2} \sum_{n=0}^{\infty} \left(n + 1 - \frac{2h_n}{1+k_n} \right) \sum_{m=0}^n (\bar{C}_{nm} \cdot \cos m\lambda + \bar{S}_{nm} \cdot \sin m\lambda) \cdot \bar{P}_{nm}(\cos\theta) \quad (8)$$

where h_n and k_n are the Love numbers for the overall elastic response of the Earth from the preliminary reference earth model (PREM). Due to the correction of the geocenter parameters from GRACE data to the coefficients C_{10} , C_{11} and S_{11} , the corresponding value of k_1 was changed to 0.021. The values of gravity disturbance have also been fixed by the *gain factor* (Landerer and Swenson, 2012) for the examined region, which was equal to 1.06. In our research area, no earthquake with magnitude above 8.5 has been observed. Further, the effect of postglacial uplift is relatively small. Hence, it was decided not to make related corrections.

To analyse the time series of GRACE mission, all eight types of non-isotropic filtration of DDK (DDK1–DDK8) were used, as well as Gaussian filtration with the following radii (R): 200, 300, 400, 500 and 600 km. Datasets from RL05a and RL06 releases were considered separately for solutions from CSR, GFZ and JPL centres.




Figure 10. Mean gravity disturbance values and standard deviation (dispersion) based on all types of filtration. Source: own study

On comparing the discrepancies between gravity disturbances observed by GRACE and FG5 (corrected for hydrological effect), a significant difference can be seen between the time series from 2005 to 2009 and from 2010 to 2016 in ground data (red dots in Figure 10), regardless of the type of filtration. The discrepancies observed in these periods result mainly from a major hydrological flood that happened during those times. This rapid increase in dg is not noticed very clearly by GRACE sensors. Substantial seasonal fluctuations in amplitudes, caused by large-scale changes in the water level of the Vistula basin, affect the suppression of information related to the flood in 2010. To compare the data from satellite and terrestrial sensors properly, it is needed to exclude the effects that are modellable and do not appear in local ground observations. These effects are periodic (annual, semi-annual and quarterly) changes of amplitudes in observations recorded by GRACE. Eliminating them allows more effective analysis regarding the comparison of data from different sensors.

To remove the effect caused by seasonal amplitude changes of continental hydrology, the signal had to be approximated with sinusoidal functions. This was done using the least-squares spectral analysis (LSSA) method (Vaníček, 1969, 1971) based on modelling of two waves with annual and semi-annual amplitude parameters determined using the Gauss–Markov model. Decomposition of the observed signal was made in accordance with the methodology proposed in Kuczynska-Siehién et al. (2019). This approach enables eliminating time series periodicity for both GRACE and absolute measurement datasets (Figure 11).




Figure 11. Mean gravity disturbance values after signal decomposition, and standard deviation (dispersion) based on all types of filtration. Source: own study

3.2. Analysis of residuals and time series consistency

After cleaning the datasets, the variability analysis of individual signals was performed in terms of the selected filtration type. To distinguish all discrepancies between FG5 absolute measurements and filtered observations from GRACE, the graphs shown in Figure 12 present

the differences between them. The left graph depicts the residues of RL06 release and the right one depicts the residues of RL05a release.




Figure 12 Residual diagram AG-GRACE RL06 (left) and RL05a (right) for DDK1-8 filtration (rows: 1–8, 14–21, 27–34) and Gaussian 200–600 km (rows: 9–13, 22–26, 35–39). Source: own study

The performances of Gaussian filter with smoothing radius equal to 200 km (rows: 9, 22, 35) and DDK8 (rows: 8, 21, 34) are clearly different from others. Furthermore, it can be seen that the discrepancies occurring in 2010 were not fully corrected due to the changes in groundwater level. This is because of the intense floods that occurred in that year. To determine which of the filtered GRACE time series best fits the AG measurements, the mean square error (RMSE) for each of these series was calculated based on the residues according to the formula:

$$RMSE = \sqrt{\frac{1}{N} \sum_{n=1}^N (\delta g_n^{GRACE} - \delta g_n^{AG})^2} \quad (9)$$

Subsequently, Pearson's correlation coefficients were estimated for all calculated variants (on account of applied filters, processing centres) of gravimetric disturbance. However, since the GRACE solutions were delivered monthly, there are some phase shifts between the signals observed by satellite and ground sensors. Therefore, the analysis of signal compatibility was completed with the normalised cross-correlation ($Xcorr$) coefficients:

$$xcorr(\delta g^{AG}(t), \delta g^{GRACE}(t + \tau)) = \frac{E[(\delta g_t^{AG} - \mu(\delta g^{AG}))(\delta g_{t+\tau}^{GRACE} - \mu(\delta g^{GRACE}))]}{\sigma(\delta g^{GRACE})\sigma(\delta g^{AG})} \quad (10)$$

where E is the expected value of the given expression, σ is the standard deviation and μ is the average value, all depending on the time shift τ . In our paper, we have chosen an $Xcorr$ value that was a maximum in ± 3 months interval of possible lags between the examined time series. So, this lag value is less than 3 (months). The results of all the statistics listed above are summarised in Table 1.

Table 1. The statistics of time series comparison

RL06											RL05									
Xcorr			RMS (μGal)			Pearson corr			Filter type	Xcorr			RMS (μGal)			Pearson corr				
CSR	GFZ	JPL	CSR	GFZ	JPL	CSR	GFZ	JPL		CSR	GFZ	JPL	CSR	GFZ	JPL	CSR	GFZ	JPL		
2005-2016	0.39	0.55	0.37	5.15	5.09	5.26	0.15	0.13	0.11	DDK1	0.26	0.52	0.15	5.52	5.19	5.48	0.09	0.20	0.08	
	0.60	0.64	0.59	4.74	4.67	4.87	0.33	0.24	0.29	DDK2	0.57	0.71	0.49	5.10	4.77	5.00	0.27	0.38	0.29	
	0.77	0.70	0.72	4.59	4.44	4.70	0.40	0.28	0.37	DDK3	0.76	0.80	0.73	4.78	4.51	4.65	0.39	0.47	0.43	
	0.79	0.70	0.73	4.59	4.43	4.70	0.40	0.27	0.37	DDK4	0.78	0.80	0.76	4.79	4.56	4.66	0.40	0.46	0.43	
	0.81	0.70	0.75	4.65	4.38	4.71	0.39	0.24	0.36	DDK5	0.79	0.78	0.79	5.04	4.98	4.96	0.33	0.33	0.38	
	0.81	0.69	0.76	4.76	4.36	4.69	0.36	0.23	0.36	DDK6	0.78	0.76	0.79	5.31	5.32	5.25	0.27	0.24	0.33	
	0.78	0.68	0.79	5.26	4.79	4.71	0.27	0.20	0.33	DDK7	0.65	0.63	0.74	6.67	6.52	6.28	0.07	-0.03	0.22	
	0.76	0.67	0.78	5.62	5.55	4.91	0.22	0.18	0.29	DDK8	0.48	0.48	0.68	7.75	7.17	6.83	0.00	-0.12	0.18	
	0.72	0.67	0.79	6.16	6.90	6.11	0.20	0.09	0.22	GAUSS R=	200 km	0.24	0.78	0.13	7.54	6.69	7.03	0.04	0.26	0.16
	0.75	0.68	0.72	4.63	4.58	4.67	0.34	0.17	0.32		300 km	0.61	0.80	0.73	5.05	4.98	4.95	0.27	0.28	0.31
	0.65	0.64	0.60	4.78	4.70	4.88	0.28	0.16	0.24		400 km	0.50	0.72	0.56	5.07	4.89	5.05	0.24	0.30	0.24
	0.56	0.61	0.54	4.89	4.82	4.99	0.22	0.14	0.17		500 km	0.41	0.64	0.39	5.14	4.88	5.15	0.19	0.30	0.18
	0.50	0.59	0.50	4.99	4.90	5.07	0.16	0.12	0.12		600 km	0.37	0.61	0.30	5.20	4.91	5.23	0.15	0.27	0.13
RL06											RL05									
Xcorr			RMS (μGal)			Pearson corr			Filter type	Xcorr			RMS (μGal)			Pearson corr				
CSR	GFZ	JPL	CSR	GFZ	JPL	CSR	GFZ	JPL		CSR	GFZ	JPL	CSR	GFZ	JPL	CSR	GFZ	JPL		
2005-2016 deseasonalised	0.24	0.16	0.41	4.25	4.91	4.27	0.48	0.16	0.48	DDK1	0.25	0.50	0.34	4.56	4.52	4.53	0.42	0.44	0.45	
	0.62	0.17	0.70	3.83	4.59	3.88	0.62	0.28	0.61	DDK2	0.58	0.68	0.64	4.27	4.22	4.21	0.53	0.54	0.56	
	0.77	0.29	0.74	3.75	4.52	3.75	0.63	0.31	0.63	DDK3	0.73	0.76	0.68	4.15	4.08	4.16	0.56	0.59	0.56	
	0.80	0.32	0.74	3.76	4.53	3.77	0.62	0.30	0.62	DDK4	0.77	0.79	0.69	4.17	4.09	4.22	0.56	0.58	0.54	
	0.84	0.38	0.76	3.85	4.51	3.83	0.59	0.26	0.60	DDK5	0.82	0.84	0.79	4.38	4.33	4.50	0.49	0.50	0.45	
	0.83	0.40	0.79	4.00	4.51	3.87	0.55	0.25	0.59	DDK6	0.81	0.84	0.81	4.62	4.60	4.74	0.40	0.40	0.40	
	0.78	0.43	0.79	4.74	5.08	4.18	0.37	0.21	0.49	DDK7	0.72	0.76	0.77	6.00	5.81	5.66	0.11	0.04	0.28	
	0.75	0.41	0.75	5.25	5.87	4.55	0.30	0.18	0.39	DDK8	0.62	0.68	0.74	7.10	6.54	6.21	0.01	-0.09	0.23	
	0.62	0.49	0.79	5.80	7.09	5.43	0.25	0.09	0.34	GAUSS R=	200 km	0.40	0.77	0.17	6.67	6.79	7.26	0.18	0.23	0.09
	0.73	0.33	0.71	3.89	4.78	3.92	0.61	0.18	0.61		300 km	0.68	0.84	0.78	4.35	4.58	4.44	0.51	0.40	0.46
	0.51	0.09	0.48	4.02	4.81	4.08	0.58	0.18	0.57		400 km	0.41	0.70	0.56	4.38	4.41	4.48	0.51	0.50	0.46
	0.24	0.17	0.35	4.18	4.88	4.21	0.53	0.15	0.53		500 km	0.15	0.42	0.28	4.49	4.45	4.55	0.48	0.49	0.44
	0.11	0.25	0.21	4.31	4.93	4.32	0.48	0.12	0.49		600 km	0.17	0.25	0.11	4.59	4.53	4.63	0.44	0.47	0.42

Performance:

good

avg

bad

It can be seen that with RL05a dataset, all processing centres show quite a large consistency of the results. They reveal similar values of both indexes, correlation and RMS. DDK3–6 filters fare very well in this comparison. They are characterised by a cross-correlation coefficient of 0.7–0.8. The RMSE for these sets is approx. 4.5–5.2 μ Gal before signal decomposition. This values decreases to 4.1–4.7 μ Gal after removing the seasonal effects. An alternative to these types of filtration may be Gaussian filtration with a smoothing radius of $R = 300$ or 400 km (in GFZ solution). In all other cases, there is no balance between preserving geophysical information and removing orbital or seasonal hydrological effects. Although RMSE remains at 4.5 μ Gal, the correlation coefficients drop significantly below 0.5. This means there is no relationship between the signals.

For the RL06 release, DDK3–6 filters are still the best performing ones. The relation between GRACE and FG5 time series remained strong with 0.7–0.8 X_{corr} values for CSR and JPL centres. This release had also lower RMS error varying in the range of 3.7–4.0 μGal . The amount of observational noise decreased as compared to RL05a. In turn, Gaussian filtration gave satisfactory results only for a smoothing radius of 300 km in any data processing centre.

On comparing the results from the research centres, the dataset from GFZ clearly stands out from the rest. Before removing seasonal impacts, cross-correlation coefficients did not differ much from those obtained for JPL and CSR. However, after eliminating periodicity effects, the values of these factors dropped down. Thus, RL06 data processing strategy provided by GFZ turns out to be inefficient in the case of research in AGO Józefosław area.

4. CONCLUSIONS

When considering the compatibility between terrestrial gravity measurements and GRACE filtered data, it can be noticed that the change in the water table from –11 m to about –8 m below the Earth's surface is not recorded from a satellite's level because the phenomenon is purely local. It should be eliminated at the stage of comparing GRACE solutions with in situ data.

Removing the periodic phenomena of gravity changes associated with different seasons from time series enabled investigation of local environmental changes. To effectively perform this process, it was sufficient to use proper sinusoidal function fit.

In the case of Gaussian filtration, the best results are obtained by a smoothing radius equal to 300 km, which agrees with the recommendations posted by official data processing centres. Other radii of this kind of filtration cause too much data averaging in the study area. Thus, they should not be used because of unsatisfactory performance.

Considering the latest GRACE reprocessed dataset, DDK3–DDK6 filters published by the CSR and the JPL are characterised by a high cross-correlation coefficient at the level of 0.8 and a satisfactory RMSE in the range of 3.7–4.0 μGal , i.e. lower than twice the measurement made by the FG5 gravimeter. For the same filters in the RL05a data version, all three computing centres present good results for both cross-correlation coefficient and RMSE, with values of 0.7–0.8 and 4.1–4.7 μGal , respectively. Therefore, the conclusion is that satellite observations made by GRACE mission properly filtered can be successfully used in studies on the JOZE observatory.

Furthermore, the right selection of data processing strategy is of additional importance. In the RL06 version for GFZ, after signal decomposition, the overall results are worse. Moreover, DDK1–2 filtration types present too intense blurring of geophysical artefacts and could only be used in large oceanic or river basin areas.

The choice of an optimal filtration type and the accuracy of GRACE solutions resulting from it are extremely important in the context of establishing International Geomagnetic Reference Field (IGRF) system and the maintenance of basic gravimetric network in Poland.

REFERENCES

- Abe, M, C Kroner, S Petrovic, F Barthelmes, A Weise, B Creutzfeldt, T Jahr, G Jentzsch, H Wilmes, and H Wziontek. 2012. A Comparison of GRACE-Derived Temporal Gravity Variations with Observations of Six European Superconducting Gravimeters. *Geophysical Journal International*. 545–56. <https://doi.org/10.1111/j.1365-246X.2012.05641.x>.
- Chen, J. L., Wilson, C. R., & Seo, K. W. 2006. Optimized smoothing of Gravity Recovery and Climate Experiment (GRACE) time-variable gravity observations. *Journal of Geophysical*

Research: Solid Earth, 111(B6).

Cheng, Minkang, Byron D. Tapley, and John C. Ries. 2013. "Deceleration in the Earth's Oblateness." *Journal of Geophysical Research: Solid Earth* 118 (2): 740–47. <https://doi.org/10.1002/jgrb.50058>.

Creutzfeldt, Benjamin. 2010. "The Effect of Water Storages on Temporal Gravity Measurements and the Benefits for Hydrology," 106. <http://opus.kobv.de/ubp/volltexte/2010/4857/>.

Crossley, David, Caroline de Linage, Jacques Hinderer, Jean-Paul Boy, and James Famiglietti. 2012. "A Comparison of the Gravity Field over Central Europe from Superconducting Gravimeters, GRACE and Global Hydrological Models, Using EOF Analysis." *Geophysical Journal International* 189 (2): 877–97. <https://doi.org/10.1111/j.1365-246X.2012.05404.x>.

Dahle, Christoph, Frank Flechtner, Christian Gruber, Daniel König, Rolf König, and Grzegorz Michalak. 2013. "GFZ GRACE Level-2 Processing Standards Document for Level-2 Product Release 0005," <https://doi.org/10.2312/GFZ.b103-1202-25>.

Dahle, Christoph, Michael Murböck, Frank Flechtner, Henryk Dobslaw, Grzegorz Michalak, Karl Hans Neumayer, Oleh Abryksov, et al. 2019. "The GFZ GRACE RL06 Monthly Gravity Field Time Series: Processing Details and Quality Assessment," 1–22. <https://doi.org/10.3390/rs11182116>.

Duan. 2009. "On the Postprocessing Removal of Correlated Errors in GRACE Temporal Gravity Field Solutions," 1095–1106. <https://doi.org/10.1007/s00190-009-0327-0>.

Godah, Walyeldeem, and Jan Krynski. 2017. "On the Estimation of Physical Height Changes Using GRACE Satellite Mission Data – A Case Study of Central Europe" 66 (2): 211–26. <https://doi.org/10.1515/geocart-2017-0013>.

Godah, Walyeldeem, Jan Krynski, and Malgorzata Szelachowska. 2018. "PT of Global Geopotential Models (GGMs). It Is Also Aimed at Improving Quasigeoid Heights Determined," <https://doi.org/10.1016/j.jappgeo.2018.03.002>.

Godah, Walyeldeem, Malgorzata Szelachowska, and Jan Krynski. 2015. "On the Selection of GRACE-Based GGMs and a Filtering Method for Estimating Mass Variations in the Earth System over Poland" 7 (1): 5–14.

Horvath, Alexander, Michael Murböck, Roland Pail, and Martin Horwath. 2018. "Decorrelation of GRACE Time Variable Gravity Field Solutions Using Full Covariance Information," 1–16. <https://doi.org/10.3390/geosciences8090323>.

Jekeli, C. 1981. *Alternative Methods to Smooth the Earth's Gravity Field*. Reports of the Department of Geodetic Science. Columbus, Ohio : Ohio State University Dept. of Geodetic Science and Surveying.

Kloch-Glowka, Grazyna, Jan Krynski, and Malgorzata Szelachowska. 2012. "Time Variations of the Gravity Field over Europe Obtained from GRACE Data" 92 (1): 175–90.

Kuczynska-Sieghien, Joanna, Dimitrios Piretzidis, Michael G Sideris, and Tomasz Olszak. 2019. "Monitoring of Extreme Land Hydrology Events in Central Poland Using GRACE , Land Surface Models and Absolute Gravity Data."

Kusche, Jürgen. 2007. "Approximate Decorrelation and Non-Isotropic Smoothing of Time-Variable GRACE-Type Gravity Field Models." *Journal of Geodesy* 81 (11): 733–49. <https://doi.org/10.1007/s00190-007-0143-3>.

Kusche, J., Schmidt, R., Petrovic, S., & Rietbroek, R. (2009). Decorrelated GRACE time-

variable gravity solutions by GFZ, and their validation using a hydrological model. *Journal of Geodesy*, 83(10), 903-913.

Landerer, F. W., & Swenson, S. C. (2012). Accuracy of scaled GRACE terrestrial water storage estimates. *Water Resources Research*, 48(4).

Neumeyer, J, F Barthelmes, C Kroner, and S Petrovic. 2005. "Analysis of Gravity Field Variations Derived from Superconducting Gravimeter Recordings, GRACE Satellite and Hydrological Models at Selected European Sites," no. 1: 1–21.

Ries, J., S. Bettadpur, R. Eanes, Z. Kang, U. Ko, C. McCullough, P. Nagel, et al. 2016. "The Combined Gravity Model GGM05C." GFZ Data Services.

Sakumura, C, S Bettadpur, and S Bruinsma. 2014. "Ensemble Prediction and Intercomparison Analysis of GRACE Time-Variable Gravity Field Models," 1389–97. <https://doi.org/10.1002/2013GL058632.1>.

Savannah S. Cooley; Felix W. Landerer. 2019. "GRACE D-103133 Gravity Recovery and Climate Experiment Level-3 Data Product User Handbook."

Swenson S, Wahr J (2006) Post-processing removal of correlated errors in GRACE data. *Geophys Res Lett* 33:L08402. doi: 10.1029/2005GL025285

Swenson, Sean, Don Chambers, and John Wahr. 2008. "Estimating Geocenter Variations from a Combination of GRACE and Ocean Model Output." *Journal of Geophysical Research: Solid Earth* 113 (8): 1–12. <https://doi.org/10.1029/2007JB005338>.

Vaníček. 1971. "Further Development and Properties of the Spectral Analysis by Least-Squares." *Astrophysics and Space Science* 12 (1): 10–33. <https://doi.org/10.1007/BF00656134>.

Vaníček, Petr. 1969. "Approximate Spectral Analysis by Least-Squares Fit." *Astrophysics and Space Science* 4 (4): 387–91. <https://doi.org/10.1007/BF00651344>.

Vishwakarma, Bramha Dutt, and Balaji Devaraju. 2018. "What Is the Spatial Resolution of GRACE Satellite Products for Hydrology?," <https://doi.org/10.3390/rs10060852>.

Wahr. 1998. "Time Variability of the Earth's Gravity Field" 103: 205–29.

Received: 2020-05-27

Reviewed: 2020-07-08 (M. Biryło), 2020-08-01 (R. Gross)

Accepted: 2020-08-25

Comparison features importance for temporal and spatial-temporal approaches in GRACE and GRACE-FO signal reconstruction based on GLDAS data

Viktor Szabó

Department of Geodesy and Geodetic Astronomy,
Warsaw University of Technology,
Warszawa, Poland
Email: viktor.szabo.dokt@pw.edu.pl

Abstract: Machine learning algorithms can effectively learn the complex relationships between various input variables from the global land data assimilation system (GLDAS) and the total water storage (TWS) observed by gravity recovery and climate experiment (GRACE) and GRACE-FO (follow-on) missions. As the TWS depends on various features, a serious question arises about the importance of used variables for reconstruction. Furthermore, will the variables used for the reconstruction be equally significant for grid-based and basin-based analyses? This work examined the importance of individual predictors for the temporal and spatial-temporal approach over 254 river basins using GRACE and GRACE-FO data as target and GLDAS data as predictors. The extreme gradient boosting (XGBoost) algorithm was used to reconstruct TWS. Results were evaluated with root-mean-square error, normalised root-mean-square error, Pearson correlation coefficient, Nash-Sutcliffe efficiency, and Kolmogorov-Smirnow-test metrics. Model output influence was checked by the model-agnostic version of the feature importance and by Shapley additive explanations (SHAP).

Keywords: total water storage; TWS; global land data assimilation system; GRACE; GRACE-FO; features importance; extreme gradient boosting; XGBoost; Shapley additive explanations; SHAP.

Reference to this paper should be made as follows: Szabó, V. (2023) 'Comparison features importance for temporal and spatial-temporal approaches in GRACE and GRACE-FO signal reconstruction based on GLDAS data', *Int. J. Hydrology Science and Technology*, Vol. 16, No. 4, pp.370–389.

Biographical notes: Viktor Szabó is a researcher and data scientist. He is an expert in physical geodesy, satellite gravimetry, gravity field modelling, artificial intelligence, neural networks, and remote sensing. He has a strong background in high-dimensional classifiers, regression models, clustering algorithms, recommender systems, time-series analysis, Bayesian inference, text analytics, knowledge graphs, representation learning (embeddings), computer vision, GIS or social network analysis.

1 Introduction

Global satellite gravity measurements provide unique information regarding gravity changes caused by the mass transport over the Earth's surface. During last 19 years satellite missions gravity recovery and climate experiment (GRACE) (Tapley et al., 2004) and GRACE follow-on (GRACE-FO) (Flechtner et al., 2016) have been monitoring changes of total water storage (TWS) (Wahr et al., 1998), enabling the creation of many applications used in hydrological monitoring. The almost one-year-long gap between GRACE and GRACE-FO has raised questions about the future of GRACE-FO observation and hence understanding of the constant ongoing climate change. Along with the growing computing capabilities of computers, the importance of using machine learning methods in solving the problems related to signal reconstruction grows. It is of crucial importance that after the completion of the GRACE-FO mission planned for five years, it will be possible to map the GRACE-FO signal based on the existing data and to conduct further research related to the observations of the hydrological modelling. A growing interest in using learning-based models in hydrological applications gives new opportunities to resolve the traditionally complex problems, including data reconstruction (Hamshaw et al., 2018).

The implementation of machine learning models has been presented in several works. The first trials in 2011 using empirical orthogonal functions (EOF) were presented in Becker et al. (2011), where historical data from the Amazon basin was used. The reconstruction of TWS time series of 60 selected river basins was presented in Sun et al. (2020a). This publication presented a comprehensive comparison of TWS reconstruction using deep neural network (DNN), seasonal autoregressive integrated moving average model (SARIMAX) and machine learning (MLR) algorithms in a temporal algorithm. Seyoum et al. (2019) decision trees were used to reproduce high-resolution groundwater level anomaly (GWLA), improving global land data assimilation system (GLDAS) data with in situ observations. The spatial-temporal approach was used by Jing et al. (2020) in case study for the Nile river basin. The algorithms using random forest, extreme gradient boosting (XGBoost) and Logistic regression created a benchmark for highly accurate predictor-based reconstruction of time variation of such hydrological parameters as Snow depth water equivalent, surface soil moisture storage, root zone soil moisture storage, profile soil moisture storage, plant canopy surface water, ground water storage from GLDAS-2 dataset. Sun et al. (2020b) presented the reconstruction of TWS using NOAH and CLSM data for the largest river basins in the US, for which the predictor importance was calculated. Artificial neural networks (ANN) was also used by Seyoum and Milewski (2017). Convolutional neural network (CNN) performance was presented by Irrgang et al. (2020) and Mo et al. (2021). A research on this topic regarding the African river basins was conducted by Ahmed et al. (2019). Multilayer perceptron (MLP) networks and ANN architecture were used in predicting groundwater changes by Sun (2013). Used CNN-based model architectures, VGG16, Unet, and Segnet (Sun et al., 2019) for the India area proved the effectiveness of encoder-decoder networks in TWS reconstruction.

TWS is a complex effect strongly related to many parameters. It is essential to choose the variables used for TWS signal reconstruction. Also is crucial to find an answer that variables used for the reconstruction can be equally significant for grid-based and basin-based analysis. Machine learning predictive models are often treated as black boxes that can be automatically trained without explanation about used data impact on predicted



results. Introduction of explainable artificial intelligence (XAI) methods provide benefit to research society as a guide and benchmark for future analysis. In this work, the importance of individual predictors for the temporal and spatial-temporal approach was examined. The TWS signal was reconstructed using GRACE and GRACE-FO RL06 data as target and GLDAS-Noah model data as predictors. Data from 254 river basins areas were selected for both examined approaches. The XGBoost algorithm was used to reconstruct ΔTWS and model the relationship between climate variables. And then, last but not least, the precision metrics were determined, and finally, the importance of the individual variables used was calculated. All steps in the proposed research lead to the answer to the posed questions: Are there variables of greater importance than others in the case of reconstructing ΔTWS signal from GLDAS data using ML methods? Furthermore, what are the differences in the importance of individual variables used for the signal reconstruction between grid-based and basin-based analyses?

2 Data and methods

2.1 Experiment overview

The existing research on the GRACE topic can be divided into grid-based and basin-based analyses. The first type of research relates to time series analyses over each grid (point) cell. The second type introduces feature mapping for the entire catchment area of a given basin. In regression modelling, this leads to the division into the application of algorithms for entire catchments called temporal or for individual points in given grid cells called spatial-temporal. The general idea of the experiment is based on the use of linear regression to reconstruct the ΔTWS based on the available predictors from the GLDAS hydrological model and examining the impact of grid-based and basin-based algorithm type on variable importance. The machine learning process requires the division of data into a training set and a target. The training set contains the variables based on which the weights for the model will be trained. Expected results ‘target’, otherwise known as ‘labels,’ are continuous variables that will be predicted as output. In this case, ΔTWS values, determined based on GRACE data, were assumed as expected results and GLDAS data were used as predictors. Since the GRACE data to be used as labels were stored in the form of spherical harmonic product, in the first step, it was necessary to develop these data by applying appropriate corrections and filtering, which is described in detail in sub-chapter 2.2. The scheme of the experiment is shown in Figure 1. The experiment consisted of the preparation and elaboration of training data, training and evaluation of models, and determination of significant variables.

Training data from the GLDAS model was standardised and concatenated with the target. ΔTWS was modelled using two different approaches for which global precision metrics were determined and their spatial distribution for each of the approaches. The research area was limited to 254 selected river basins, shown in Figure 2, with different climate, area and location. Major river basins of the world were downloaded from The World Bank website (<https://www.worldbank.org/en/home>).

Figure 1 Scheme of the experiment (see online version for colours)**Figure 2** Global river basins selected to experiment (see online version for colours)

2.2 Target GRACE data

Data from the GRACE and GRACE-FO missions was collected from the International Center for Global Earth Models website (<http://icgem.gfz-potsdam.de/home>) as spherical harmonics coefficients. Spherical harmonic coefficients are a quantity that varies with position on the surface of a sphere. Due to this fact, it is possible to quickly determine the value described by a given function in a place with specific coordinates on the sphere. The study used RL06 data (Dahle et al., 2013) from April 2002 to January 2021 distributed by the Center for Space Research (CSR). Data was used in the maximum

degree/order of expansion equal to 96, corresponding to a spatial resolution of about 300 km. Terrestrial and oceanic TWS (Wahr et al., 1998) grids are processed a specific filter that is tuned to filter out noise as well as possible while maintaining true geophysical signals. The formula for determining the total water equivalent, which is the sum of all above and below surface water storages, including canopy water, rivers and lakes, soil moisture and groundwater, is as follows:

$$\Delta TWS(\theta, \lambda) = \frac{\rho_e R}{3} \sum_{n=0}^{\infty} \frac{2n+1}{1+k'} \sum_{m=0}^n (\Delta \bar{C}_{nm} \cdot \cos m\lambda + \Delta \bar{S}_{nm} \cdot \sin m\lambda) \cdot \bar{P}_{nm}(\cos \theta), \quad (1)$$

where (θ, λ) are geographical co-latitude and longitude of this point, R stands for Earth reference radius defined in International Earth Rotation and Reference Systems Service Convention (IERS2010), $\bar{C}_{nm}, \bar{S}_{nm}$ are the normalised harmonic coefficients of the gravity potential expansion (Stokes' coefficients), $\bar{P}_{nm}(\cos \theta)$ are the Legendre polynomials of n^{th} degree and m^{th} order and k' represents the elastic Earth parameter is called Love's numbers, taking into account the deformation of the Earth caused by load effects and ρ_e is average soil density (Wahr et al., 1998). The ΔC_{nm} and ΔS_{nm} , representing changes the in gravity field, were calculated by excluding the static part of the gravity field using GGM05C (Ries et al., 2016) model. In pursuance of the technical remarks TN-11 and TN-07, GRACE coefficients localising the centre of mass (C10, C11, S11) and the gravimetric flattening of the Earth (C20) (Swenson et al., 2008) have been substituted with the coefficients determined using satellite laser ranging (SLR) measurements (Cheng et al., 2013). Corrections were not introduced to the C21 and S21 coefficients due to the inclusion of a linear model of polar motion in the GRACE RL06 data (Dahle et al., 2019). An anisotropic filtration with DDK2 filter was used (Kusche, 2007) due to the compromise between the stability and accuracy of solutions (Kusche et al., 2009; Szabó and Marjańska, 2020).

2.3 Predictors land surface model data

Determining ΔTWS is a complex process. According to the definition, it will correspond to the sum of all above and below surface water storage, including canopy water, rivers, and lakes, soil moisture, and groundwater. However, this assumption does not consider the interplay of climate, meteorological and environmental indicators. According to previous research (Hamshaw et al., 2018; Sun et al., 2020a, 2020b; Jing et al., 2020), where it was shown that ML methods based on methods could successfully learn relationships between various variables and catch correlation with a target. This research is focused on understanding the complexity between variables caught by machine learning models, which can be significantly different from human understanding, so all variables provided by GLDAS model were used to ΔTWS modelling.

GLDAS models provide many important variables of land hydrology at different spatial and temporal scales in user-friendly global grids. Comparisons of data from GRACE and GLDAS show high temporal agreement and slight differences in amplitudes, which contributes to the favourable use of these data in global hydrological studies (Scanlon et al., 2018). Kuczynska-Siehien et al. (2019) shows a correlation between different GLDAS models, GRACE products, and terrestrial gravity

measurements. Because GLDAS-Noah provided a high correlation with gravity variability from GRACE in this case as trained data were used variables from GLDAS-Noah (v2.1) land surface model (Rodell et al., 2005). GLDAS-Noah (v2.1) monthly solutions (1° , dataset: GLDAS_NOAH10_M) were downloaded from Earth Data – NASA website (<https://disc.gsfc.nasa.gov/>) from January 2002 to January 2021. The list of variables used for TWS modelling from GLDAS is presented in Table 1.

Table 1 GLDAS parameters

<i>Variable name</i>	<i>Unit</i>	<i>Variable explain</i>
Lat, long	[°]	Geodetic coordinates
date	[dd-mm-yyyy]	Epoch of measurements
Swnet_tavg, Lwnet_tavg	[W m ⁻²]	Surface net downward shortwave /longwave flux
Qle_tavg, Qh_tavg	[W m ⁻²]	Surface upward latent/sensible heat flux
Qg_tavg	[W m ⁻²]	Downward heat flux in soil
Snowf_tavg, Rainf_tavg, Evap_tavg	[kg m ⁻² s ⁻¹]	Snowfall/rainfall/water evaporation flux
Qs_acc, Qsb_acc	[kg m ⁻² s ⁻¹]	Surface/subsurface runoff amount
Qsm_acc	[kg m ⁻² s ⁻¹]	Surface snow melt amount
AvgSurfT_inst	[K]	Surface temperature
SWE_inst	[kg m ⁻²]	Surface snow amount
SnowDepth_inst	[M]	Surface snow thickness
SoilMoi0_10 cm_inst, SoilMoi10_40 cm_inst, SoilMoi40_100 cm_inst SoilMoi100_200 cm_inst	[kg m ⁻²]	Soil moisture content at different layers
Albedo_inst	[%]	Surface albedo
SoilTMP0_10 cm_inst, SoilTMP10_40 cm_inst, SoilTMP40_100 cm_inst, SoilTMP100_200 cm_inst	[K]	Soil temperature at different layers
PotEvap_tavg	[W m ⁻²]	Potential evaporation flux
ECanop_tavg,	[W m ⁻²]	Evaporation flux from canopy
Tveg_tavg	[W m ⁻²]	Transpiration flux from veg
ESoil_tavg	[W m ⁻²]	Evaporation flux from soil
RootMoist_inst	[kg m ⁻²]	Root zone soil moisture
CanopInt_inst	[kg m ⁻²]	Canopy water amount
Wind_f_inst	[m/s]	Wind speed
Rainf_f_tavg	[kg m ⁻² s ⁻¹]	Precipitation flux
Tair_f_inst	[K]	Air temperature
Qair_f_inst	[kg/kg]	Specific humidity
Psurf_f_inst	[Pa]	Surface air pressure
SWdown_f_tavg, LWdown_f_tavg	[W m ⁻²]	Surface downwelling shortwave/ longwave flux in air

2.4 Features selection and processing

Feature engineering is the process of selecting and scaling variables to build the machine learning model. It makes the model easier to interpret and reduces overfitting. Different techniques of feature engineering might work better with some algorithms. During this experiment, techniques such as imputation, standardisation, grouping, time transformation and encoding were used. In this study, training data was divided into numerical variables with continuous characteristics and categorical variables, i.e., those with two or more groups or categories. During comparing monthly solutions from GRACE or GRACE-FO fields with the GLDAS model, monthly sampling needs to be matched between the datasets. In the first step, the observations for the same epochs for GRACE and GLDAS were averaged. Since the data had to be prepared for point-based and basin-based analyses, each element from the training data and the target was assigned to a given river basin. Each river basin has been encoded by converting the river name into a unique ID with becoming a categorical variable. A parameter related to the river basin area has been added to numerical variables as additional column. In the temporal-based approach, data were aggregated against a given river basin using averages so that each river basin was represented by a different time series. Parameters Lat and Long were averaged as a centroid of a river basin in the temporal approach, which gives us the only difference in variables between these approaches. Because variables measured at different scales do not contribute equally to the model fitting and model learned function and might create a bias thus, to deal with this potential problem, feature-wise standardisation is usually used prior to model fitting. Each numerical variable was standardised by removing mean divided by the standard deviation. Standard scaler is described by the following equation.

$$z = \frac{x - \mu}{\sigma} \quad (2)$$


where x denotes a specific variable, μ is mean value of x , and σ its standard deviation. In non-sequential algorithms, it is necessary to let the machine learning model know that a feature has a cyclical characteristic. A standard method for encoding cyclical data is to transform the data into two dimensions using a sine and cosine transformation. In order to take into account the seasonal variability, the time-related variable was decomposed into sine and cosine components with annual and semi annual periods. This made it possible to break away from the data, sequence but retain the repeatability of the factors related to the Earth's circular motion. Date represented in decimal year format was transformed by applying the following equation.

$$\text{time decompose} \left\{ \begin{array}{l} \sin Annual = \sin(2 \cdot \pi \cdot \text{date}) \\ \cos Annual = \cos(2 \cdot \pi \cdot \text{date}) \\ \sin SemiAnnual = \sin(2 \cdot \pi \cdot \text{date} / 0.5) \\ \cos SemiAnnual = \cos(2 \cdot \pi \cdot \text{date} / 0.5) \end{array} \right. \quad (3)$$

During the feature selection process, a dropping collinear features operation can be found in many research works. This operation is essential because of the multicollinearity problem (Allen, 1997). Collinear features are features that are highly dependent on another feature. Due to high variance and less model interpretability, collinear features

lead to decreased generalised performance. Distribution of statistics presenting interquartile range (IQR) and mutual correlations for parameters used in this study are presented using boxplots in Figure 3.

Figure 3 (a) Distribution of statistics presenting interquartile range (b) Correlations of parameters (see online version for colours)



Similar values of correlation Figure 3 (b) for soil temperature (SoilTMP) or soil moisture (SoilMoi) of the predictors could be noticed. Since the shallow (top) soil layers have a much faster physical process than the deeper one, removing this predictor from model provides a lost significant part of the signal. Due to this study's subject and the use of sine and cosine components with semiannual periods, it was consciously decided not to drop any of these columns. Looking at Figure 3(a) a significant variance for the variables surface snow melt amount (Qsm_acc), Surface runoff amount (Qs_acc), subsurface runoff amount (Qsb_acc), surface snow amount (SWE_inst), surface snow thickness (SnowDepth_inst), Snowfall evaporation flux (Snowf_tavg) can be seen. It can be viewed in terms of outliers. These variables are clearly interdependent. High variance results from the appearance of snowfall and spring thaw, but only in temperate climatic zones, where we have the opportunity to observe four seasons. Snow variables do not appear in hot climates, hence the small range of these values between the 1st and the 3rd quantile. Variables with non-zero values regardless of latitude have clearly more stable distributions. At the end process, numerical and categorical variables were concatenated and shuffled before training.

2.5 Regression modelling

In machine learning, there are several kinds of problems where these algorithms can be applied. It is tasks such as classification, regression, clustering, object detection,


forecasting, recommendation or anomaly detection. Signal reconstruction can be addressed well by regression modelling using machine learning algorithms. A regression problem may be stated as predicting a continuous outcome variable based on the given set of predictors (or features). A regression model is a technique of creating a mathematical equation that defines y as a function of the x variables. Linear regression is the most simple and popular technique for predicting a continuous variable and can be written as:

$$Y = X\beta_1 + \beta_0 + \varepsilon, \quad (4)$$

where β_0 is the intercept, β_1 is the regression weight or coefficient associated with the predictor variable X and ε is the Gaussian noise. The literature can find many different models used in regression problems. This work aimed not to build a perfect model but get an insight into relationships in the data and create a benchmark for more complex interpretations. Based on previous research about comparing performance models and focusing on model complexity and interpretability, it was decided to use the XGBoost (Chen and Guestrin, 2016) model in this study. XGBoost regressor with the implementation of the Scikit-Learn API for Python was used to create a regression model. XGBoost is a variant of tree ensemble learner that combines gradient-based optimisation with boosting. Boosting is a method for improving model accuracy, based on the idea that it is easier to find and average many rough rules of thumb than to find a single, highly accurate prediction rule.

The data included as input for training the model has been prepared in tabular form. For each point (or basin in the temporal algorithm), a matrix was determined. The rows were following measurement epochs. The columns presented the developed variables from the GLDAS model with the encoded ID river name and the basin area. This matrix corresponds to a vector with continuous TWS variables, which was marked as a target. Then all matrices were combined into one table with dimensions equal to the number of epochs $\times$ number of points $\times$ number of variables.

Before training, a specific percentage of random data should be separated for accuracy testing and model evaluation. Since the mean values of the two groups are not significantly different it is necessary to determine test data sample size to achieve statistical significance. There are a different number of samples between the first and second approach. In the temporal approach, data aggregation per river basin significantly reduced the sample size, which questioned the correctness of the comparison. In order to be able to conclude that the A / B comparison makes sense, the minimum number of samples included in the test set was determined (Ioannidis, 2005). In order to observe a 1%–2% change in the target between the results, assuming the 95% confidence level and 80% power test, the effect size was determined, and the minimum number of samples needed for the evaluation was calculated, which constituted no less than 27% of the data. This value was arbitrarily rounded to 30%. The hyperparameters of model have been tuned with Grid Search algorithm (Shekar and Dagnew, 2019). The results achieved are presented in the next chapter.

Figure 4 Scheme of train dataset (see online version for colours)

3 Results

3.1 Model performance

The performance of the model was measured by metrics such as Nash-Sutcliffe efficiency (NSE) (Nash and Sutcliffe, 1970), Pearson correlation coefficient (CC), Kolmogorov-Smirnov-Test (KS) (Hodges, 1958), root-mean-square error (RMSE), and normalised root-mean-square error (NRMSE) as RMSE divided by annual amplitude determined as the root of the fit parameters of periodic functions (Vaníček, 1969, 1971). Parameters of periodic functions were determined using the Gauss-Markov model. Additionally the RMSE was determined using cross-validation (Refaeilzadeh and Tang, 2009) with 10 k-fold and 3 repeated. NSE is a normalised statistic determining the relative magnitude of residual variance (noise) relative to the measured data variance (information) (Nash and Sutcliffe, 1970). KS tests whether two samples are drawn from the same distribution. This statistic measures the absolute max distance (supremum) between the cumulative distribution functions (CDFs) of the two samples. The distribution is assumed to be continuous. If the KS statistic is small or the p-value is high, then we cannot reject the hypothesis that the distributions of the two samples are the same. Metrics are described by the following equations.

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - o_i)^2}, \quad (5)$$

$$NRMSE = \frac{RMSE}{\sqrt{a^2 + b^2}}, \quad (6)$$


$$NSE = 1 - \frac{\sum_{i=1}^N (y_i - o_i)^2}{\sum_{i=1}^N (o_i - \bar{o})^2}, \quad (7)$$

$$CC = \frac{\sum_{i=1}^N (y_i - \bar{y})(o_i - \bar{o})}{\sqrt{\sum_{i=1}^N (y_i - \bar{y})^2 \sum_{i=1}^N (o_i - \bar{o})^2}}, \quad (8)$$

$$KS = \sup_x |F_{1,n}(x) - F_{2,m}(x)|, \quad (9)$$

where y_i , o_i are predicted and observed true values respectively, $F_{1,n}$ and $F_{2,m}$ are the empirical distribution functions of the first and second samples respectively, and $\sup$ is the supremum function. Parameters $\bar{y}$, $\bar{o}$ are averages of predicted and observed true values respectively, and a , b are parameters of periodic functions.

Figure 5 Validation model, (a) CDF for temporal approach (b) CDF for spatial-temporal approach (c) prediction against true values for temporal approach (d) prediction against true values for spatial-temporal approach (see online version for colours)



The results of the validation demonstrate Figure 5 which shows plotting predicted values against the true value. If points are close to a diagonal line, the predicted values are more accurate. The differences between the distribution of predicted and true variables are presented using the CDFs plot and the corresponding KS metric presented in Table 2.

Table 2 Global metrics of model evaluation determined on the randomly selected test set


<i>Metrics</i>	<i>Temporal</i>	<i>Spatial-temporal</i>
NSE	0.717	0.805
CC	0.847	0.898
RMSE (cross validated) [mm]	50.320	45.974
RMSE[mm]	45.221	42.432
NRMSE	0.625	1.165
KS	0.038	0.035

Figures 5(c) and 5(d) show a highly satisfactory distribution of the density of the predicted observations against the true values. Moreover, 95% of the value is within the standard deviation limit, proving the high quality of the trained model.

The achieved results correspond to the benchmark level of the results in other works. Sun et al. (2020a) show average results of CC: 0.88–0.89, RMSE: 4.5–4.7 cm, NSE: 0.7 for the temporal approach. For spatial and temporal algorithm, Sun et al. (2020b) achieve results of Nash-Sutcliffe efficiency around 0.85, the mean correlation coefficient around 0.95 and the mean normalised root-mean-square-error about 0.09 at over the US area. For a case study of the Nile river basin with the spatial-temporal method (Jing et al., 2020) it can be observed results of RMSE: 1.4–3.47 cm, NSE: 0.54–0.94, CC: 0.79–0.97. Using CNN networks at the grid-based scale showed a very good fit of predicted results of CC = 0.94 and NSE = 0.87 at the India study area. Global metrics are similar between approaches. The achieved NSE and CC values in this work intensely converge to 1, which is satisfactory for this experiment. However, RMS at 4.5–5.0 cm does not say much about the quality of the solution. A better metric showing the ratio of the error achieved to the size of the observed phenomenon is NRMSE. The more excellent value of this metric for approach spatial-temporal results from the more significant variance of individual observations, which significantly increases this error. The KS values are small, which shows that the distribution of the predicted values by the model does not differ significantly from the real ones. Figure 6 shows statistical measures of the accuracy of fit model in spatial distribution.

The distribution of the metrics for both approaches is very similar. The spatial distribution of the metrics shows the largest RMSE for the Amazon basin. However, due to large fluctuations of ΔTWS in this area, the NRMSE index is relatively small. The regions with the weakest results for the reconstruction of ΔTWS is the Parana river in the southern regions of South America, Saskatchewan-Nelson and St. Lawrence river in the area of the Great Lakes on the border of Canada and the USA, Huang He (Yellow River), Amur, Liao in the eastern part of the Asian continent areas overlap with the Sahara desert. The better performance in humid areas than in dry areas can be seen in Higher NSE and CC values in these regions, reflected by spatial distributions of GLDAS humid related variables. The reason why XGBoost underestimates ΔTWS in these specific regions may be related to the complex anthropogenic effects on groundwater storage (GWS) and TWS. Human impact is not included in a set of predictors in this experiment, but explaining these phenomena is not the primary purpose of this work.

Figure 6 Spatial distribution of metrics, (a) NESE for temporal approach (b) NSE for spatial-temporal approach (c) RMSE for temporal approach (d) RMSE for spatial-temporal approach (e) NRMSE for temporal approach (f) NRMSE for spatial-temporal approach (g) CC for temporal approach (h) CC for spatial-temporal approach (i) KS for temporal approach (j) KS for spatial-temporal approach (see online version for colours)




3.2 Feature importance

Feature importance is techniques that assign a score to input features based on how useful they are at predicting a target variable. The permutation feature importance measurement was introduced in Breiman (2001) We can describe feature importance as the measures are based on the number of times a variable is selected for splitting, weighted by the squared improvement to the model as a result of each split, and averaged over all trees (Breiman, 2001; Friedman, 2001; Elith et al., 2008). Fisher et al. (2018) proposed a model-agnostic version of the feature importance.

$$f_{l_i} = \frac{\sum_{j: \text{node } j \text{ split on } f_i} n_{i_j}}{\sum_{k \in \text{all nodes}} n_{i_j}} \quad (10)$$

where f_{l_i} is importance of features i , n_{i_j} is importance of node j of decision tree. In XGBoost model we can calculate it in different ways, and it is worth understanding which one will be right for a given task. The Gain implies the relative contribution of the corresponding feature to the model calculated by taking each feature's contribution for each tree in the model. When compared to another feature, a higher value of this metric implies is more important for generating a prediction. The Coverage metric means the relative number of observations related to this feature. Weight is the percentage representing the relative number of times a particular feature occurs in the trees of the model. Due to the small number of categorical variables, it was decided to use gain to present the impact of variables on the model, which is presented in Figure 7.

Figure 7 Gain model, (a) temporal approach (b) for spatial-temporal approach (see online version for colours)



A different approach to this issue is presented by Shapley additive explanations (SHAP) (Lundberg and Lee, 2017). Its methods that help users interpret predictions where values are based on Shapley values, a concept coming from game theory. SHAP values are define as:

$$\Phi_i = \sum_{S \subseteq F \setminus \{i\}} \frac{|S|!(|F| - |S| - 1)!}{|F|!} [f_{S \cup \{i\}}(x_{S \cup \{i\}}) - f_S(x_S)], \quad (11)$$

where F is a set of all features, x_S represents values of input in stet S . $f_{S \cup \{i\}}$ is trained model with specific features and f_S is trained model with the feature withheld. Summing the SHAP values of each features of given observation yields the difference between the prediction of the model and the null for all possible set $S \subseteq F \setminus \{i\}$.

Figure 8 SHAP values, (a) impact on model output in temporal approach (b) impact on model output in spatial-temporal approach (c) average impact on model output magnitude in temporal approach (d) average impact on model output magnitude spatial-temporal approach (see online version for colours)




Figure 8 demonstrates top 20 variables ranked in descending order. The horizontal location shows whether the effect of that value is associated with a higher or lower prediction. The colour at Figures 8(a) and 8(b) shows whether that variable is high (red) or low (blue) for that observation.

4 Discussion

In each approach, a significant influence of variables related to time, coordinates and soil moisture can be seen. The time factor is evident due to the monotonous nature of the phenomenon, regardless of the environment. Coordinates are reflected in climatic zones. The numerical presentation of the variables reflected in the climate has a positive impact on the accuracy of the ΔTWS signal reconstruction. Due to the multicollinearity of the moisture variables at different levels, they should all be considered as variables of high importance. Another important variable that appears in each of the algorithms turns out to be the subsurface runoff amount. It is characterised by a significant variance in Figure 3 and may be critical to the estimated bias. Since no complex subsurface conditions such as fractured bedrock aquifer, high clay or stone content, deep vadose zone, were used, which are highly correlated observations for subsurface runoff, it is possible to overestimate the importance of this variable by ML model. ΔTWS represents a synthetic proxy of the dynamic of slow-responding hydrological quantities, which means that using variables with a high monthly frequency of changes may be inconvenient for ML models predictions. However, the authors of the publication (Creutzfeldt et al., 2012), in a comprehensive study on the dependence of ΔTWS dynamics on the subsurface condition using gravimetric measurements, show a stronger relationship between the runoff coefficient and TWS change than that seen with near-surface soil moisture measurements. Moreover, the authors have shown a significant correlation between flood potential amount and the runoff. Due to the fact that GRACE can be successfully used to observe gravity response for extreme precipitation (Reager and Famiglietti, 2009) it can be concluded that runoff is strictly connected with GRACE water storage estimations. It can be said with certainty that subsurface runoff impact value has been determined correctly as high. SHAP indicates the validity of the data climate forcing data concerning precipitation flux and air temperature, which is interesting because this data may represent certain aspects of observed climatology that are not fully captured in the simulated ΔTWS . The NOAA ΔTWS can be calculated as the sum of snow water, soil moisture water (in all layers), and canopy water. Features Importance determined by XGBoost and SHAP do not give much weight to canopy water amount for both trained models, which is an interesting observation. Temporal and spatial-temporal approaches are similar to each other, and differences in the impact of individual variables may be mainly due to more significant variance for spatial-temporal approaches among individual variables. The biggest differences between the impacts on the model appear for surface snow thickness, surface temperature, soil temperature at 0–10 cm, snowfall evaporation flux, evaporation flux from canopy features. However, they do not have the most significant impact on the model being trained. The variables used in the modelling have different spatial and temporal coverage. The strong dependence of the model on variables related to humidity causes an increase in errors in tropical climatic zones due to the low coverage of these variables in this area. Moreover, wind speed and air temperature variables in the top list presented by the SHAP algorithm tell us that the

climate forcing data provided by the GLDAS model is very well captured in the raw observation

The signal-to-noise ratio may be weak for basin areas smaller than $1 \times 10^5 \text{ km}^2$ (Dutt Vishwakarma et al., 2016). Despite the errors, ensuing from smoothing and signal leakage can preserve geophysical information for these areas but need special attention during the process data. Observed spatial distribution of accuracy metrics prevents to rejection of the null hypothesis of a linear relationship between the size of the river basin and the accuracy of the ΔTWS signal reconstruction based on GLDAS data.

5 Conclusions

The paper shows the reconstruction of the ΔTWS signal based on data from the GLDAS hydrological model. Trained models were evaluated with RMS (4.24–5.03 cm), NRMSE (0.62–1.16), CC (0.84–0.89), NSE (0.71–0.80), KS (0.035–0.038) precision metrics. The influence of individual variables on the model's output for the temporal and spatial-temporal approach was checked, indicating the differences between the importance of individual variables. The spatial distribution of the metrics was checked. The lowest accuracy was achieved in areas of Parana river in the southern regions of South America, Saskatchewan-Nelson and St. Lawrence river in the area of the Great Lakes on the border of Canada and the USA, Huang He (Yellow River), Amur, Liao in the eastern part of the Asian continent areas overlap with the Sahara desert. This indicates a high dependence of the trained model on humid-related variables. The aggregation of variables at the temporal approach by the river basin district influences the change of weights assigned to particular variables compared to the spatial-temporal approach. However, this change for the most influential variables remains relatively small. The work indicates the high importance for the group of predictors that make up the simulated ΔTWS : the snow water, soil moisture water (in all layers) variables. However, they are not given relevant importance for canopy water, which is also part of the simulated ΔTWS . Regardless of the approach, subsurface runoff is one of the essential variables for the models being trained. The coordinate variables perform a significant role for the models, because they reflect the influence of the climatic zones. The size of the river basin district is a significant variable for the model. However, no relationship was observed between the area of the river basin and the accuracy of ΔTWS prediction.

Trained models were able to learn the complex relationships between various inputs from the GLDAS land surface model and the ΔTWS observed by GRACE sensors with high accuracy. Successful reconstructed GRACE time series by ML algorithms can fill the gap between GRACE and GRACE-FO missions and provide useful information after the satellite gravity mission.

References

- Ahmed, M., Sultan, M., Elbayoumi, T. and Tissot, P. (2019) 'Forecasting grace data over the African watersheds using artificial neural networks', *Remote Sensing*, Vol. 11, No. 15, p.1769, doi: 10.1007/978-0-585-25657-3_37.
- Allen, M. (1997) 'The problem of multicollinearity', in *Understanding Regression Analysis*, pp.176–180, Springer US, Boston, MA, doi: 10.1007/978-0-585-25657-3_37.

- Becker, M., Meyssignac, B., Xavier, L., Cazenave, A., Alkama, R. and Decharme, B. (2011) 'Past terrestrial water storage (1980–2008) in the Amazon Basin reconstructed from GRACE and in situ river gauging data', *Hydrology and Earth System Sciences*, Vol. 15, No. 2, pp.533–546, doi:10.5194/hess-15-533-2011.
- Breiman, L. (2001) 'Random forests', *Machine Learning*, Vol. 45, No. 1, pp.5–32, doi: 10.1023/A:1010933404324.
- Chen, T. and Guestrin, C. (2016) 'Xgboost: a scalable tree boosting system', *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, pp.785–794, doi: 10.1145/2939672.2939785.
- Cheng, M., Tapley, B.D. and Ries, J.C. (2013) 'Deceleration in the Earth's oblateness', *Journal of Geophysical Research: Solid Earth*, Vol. 118, No. 2, pp.740–747, doi: 10.1002/jgrb.50058.
- Creutzfeldt, B., Ferré, T., Troch, P., Merz, B., Wziontek, H. and Güntner, A. (2012) 'Total water storage dynamics in response to climate variability and extremes: inference from long-term terrestrial gravity measurement', *Journal of Geophysical Research: Atmospheres*, Vol. 117, No. D8, doi: 10.1029/2011JD016472.
- Dahle, C. et al. (2019) *Release Notes for GFZ GRACE Level-2 Products – Version RL06* [online] <http://isd.c.gfz-potsdam.de/index.php>. (accessed 16 August 2021).
- Dahle, C., Flechtner, F., Gruber, C., König, D., König, R., Michalak, G. and Neumayer, K.H. (2013) *GFZ GRACE Level-2 Processing Standards Document for Level-2 Product Release 0005: Revised Edition*, January, doi: 10.2312/GFZ.b103-1202-25.
- Dutt Vishwakarma, B., Devaraju, B. and Sneeuw, N. (2016) 'Minimizing the effects of filtering on catchment scale GRACE solutions', *Water Resources Research*, Vol. 52, No. 8, pp.5868–5890, doi: 10.1002/2016WR018960.
- Earth Data – NASA [online] <https://disc.gsfc.nasa.gov/> (accessed 16 August 2021).
- Elith, J., Leathwick, J. R. and Hastie, T. (2008) 'A working guide to boosted regression trees', *Journal of Animal Ecology*, Vol. 77, No. 4, pp.802–813, doi: 10.1111/j.1365-2656.2008.01390.x.
- Fisher, A., Rudin, C. and Dominici, F. (2019) 'All models are wrong, but many are useful: learning a variable's importance by studying an entire class of prediction models simultaneously', *Journal of Machine Learning Research*, Vol. 20, No. 177, pp.1–81, doi:10.48550/arXiv.1801.01489.
- Flechtner, F., Neumayer, K.H., Dahle, C., Döbrowsky, H., Fagiolini, E., Raimondo, J.C. and Güntner, A. (2016) 'What can be expected from the GRACE-FO laser ranging interferometer for earth science applications?', in *Remote Sensing and Water Resources*, pp.263–280, Springer, Cham, doi: 10.1007/s10712-015-9338-y.
- Friedman, J.H. (2001) 'Greedy function approximation: a gradient boosting machine', *Annals of Statistics*, October, Vol. 29, No. 5, pp.1189–1232.
- Hamshaw, S.D., Dewoolkar, M.M., Schroth, A.W., Wemple, B.C. and Rizzo, D.M. (2018) 'A new machine-learning approach for classifying hysteresis in suspended-sediment discharge relationships using high-frequency monitoring data', *Water Resources Research*, Vol. 54, No. 6, pp.4040–4058, doi: 10.1029/2017WR022238.
- Hodges, J.L. (1958) 'The significance probability of the Smirnov two-sample test', *Arkiv för Matematik*, Vol. 3, No. 5, pp.469–486.
- International Center for Global Earth Models [online] <http://icgem.gfz-potsdam.de/home> (accessed 16 August 2021).
- Ioannidis, J.P. (2005) 'Why most published research findings are false', *PLoS Medicine*, Vol. 2, No. 8, p.e124, doi: 10.1371/journal.pmed.0020124.
- Irrgang, C., Saynisch-Wagner, J., Dill, R., Boergens, E. and Thomas, M. (2020) 'Self-validating deep learning for recovering terrestrial water storage from gravity and altimetry measurements', *Geophysical Research Letters*, Vol. 47, No. 17, e2020GL089258, doi: 10.1029/2020GL089258.

- Jing, W., Di, L., Zhao, X., Yao, L., Xia, X., Liu, Y., Li, Y. and Zhou, C. (2020) 'A data-driven approach to generate past GRACE-like terrestrial water storage solution by calibrating the land surface model simulations', *Advances in Water Resources*, Vol. 143, p.103683, doi: 10.1016/j.advwatres.2020.103683.
- Kuczynska-Sieghien, J., Piretzidis, D., Sideris, M. G., Olszak, T. and Szabó, V. (2019) 'Monitoring of extreme land hydrology events in central Poland using GRACE, land surface models and absolute gravity data', *Journal of Applied Geodesy*, Vol. 13, No. 3, pp.229–243, doi: 10.1515/jag-2019-0003.
- Kusche, J. (2007) 'Approximate decorrelation and non-isotropic smoothing of time-variable GRACE-type gravity field models', *Journal of Geodesy*, Vol. 81, No. 11, pp.733–749, doi: 10.1007/s00190-007-0143-3.
- Kusche, J., Schmidt, R., Petrovic, S. and Rietbroek, R. (2009) 'Decorrelated GRACE time-variable gravity solutions by GFZ, and their validation using a hydrological model', *Journal of Geodesy*, Vol. 83, No. 10, pp.903–913, doi: 10.1007/s00190-009-0308-3.
- Lundberg, S.M. and Lee, S.I. (2017) 'A unified approach to interpreting model predictions', *Advances in Neural Information Processing Systems*, Vol. 30, No. 2, pp.1–10.
- Mo, S., Zhong, Y., Shi, X., Feng, W., Yin, X. and Wu, J. (2021) 'Improving prediction of the terrestrial water storage anomalies during the GRACE and GRACE-FO gap with Bayesian convolutional neural networks', arXiv preprint arXiv:2101.09361.
- Nash, J.E. and Sutcliffe, J.V. (1970) 'River flow forecasting through conceptual model. Part 1 – a discussion of principles', *Journal of Hydrology*, Vol. 10, No. 3, pp.282–290, doi: /10.1016/0022-1694(70)90255-6.
- Reager, J.T. and Famiglietti, J.S. (2009) 'Global terrestrial water storage capacity and flood potential using GRACE', *Geophysical Research Letters*, Vol. 36, No. 23, doi: 10.1029/2009GL040826.
- Refaeilzadeh, P. and Tang L. (2009) 'Cross-validation', in *Encyclopedia of Database Systems*, Springer, Boston, MA, doi: 10.1007/978-0-387-39940-9_565.
- Ries, J., Bettadpur, S., Eanes, R., Kang, Z., Ko, U., McCullough, C. and Tapley, B. (2016) *The Combined Gravity Model GGM05C*, GFZ Data Services, GFZ Data Services.
- Rodell, M., Houser, P., Peters-Lidard, C., Kato, H., Kumar, S., Gottschalck, J., Ken, M. and Meng, J. (2005) 'Nasa/Noaa's global land data assimilation system (GLDAS): recent results and future plans', *Proc. ECMWF/ELDAS Workshop on Land Surface Assimilation*, pp.61–68.
- Scanlon, B.R., Zhang, Z., Save, H., Sun, A.Y., Schmied, H.M., Van Beek, L.P. and Bierkens, M.F. (2018) 'Global models underestimate large decadal declining and rising water storage trends relative to GRACE satellite data', *Proceedings of the National Academy of Sciences*, Vol. 115, No. 6, pp.E1080–E1089, doi: 10.1073/pnas.1704665115.
- Seyoum, W., Kwon, D. and Milewski, A. (2019) 'Downscaling GRACE TWSA data into high-resolution groundwater level anomaly using machine learning-based models in a glacial aquifer system', *Remote Sensing*, Vol. 11, No. 7, p.824, doi: 10.3390/rs11070824.
- Seyoum, W.M. and Milewski, A.M. (2017) 'Advances in water resources improved methods for estimating local terrestrial water dynamics from GRACE in the Northern high plains', *Advances in Water Resources*, October, Vol. 110, pp.279–290, Elsevier, doi: 10.1016/j.advwatres.2017.10.021.
- Shekar, B.H. and Dagnew, G. (2019) 'Grid search-based hyperparameter tuning and classification of microarray cancer data', *2019 Second International Conference on Advanced Computational and Communication Paradigms (ICACCP)*, pp.1–8, IEEE, doi: 10.1109/ICACCP.2019.8882943.
- Sun, A.Y. (2013) 'Predicting groundwater level changes using GRACE data', *Water Resources Research*, Vol. 49, No. 9, pp.5900–5912, doi: 10.1002/wrcr.20421.
- Sun, A.Y., Scanlon, B.R., Save, H. and Rateb, A. (2020b) 'Reconstruction of GRACE total water storage through automated machine learning', *Water Resources Research*, Vol. 57, No. 2, e2020WR028666, doi: 10.1029/2020WR028666.

- Sun, A.Y., Scanlon, B.R., Zhang, Z., Walling, D., Bhanja, S.N., Mukherjee, A. and Zhong, Z. (2019) 'Combining physically based modeling and deep learning for fusing GRACE satellite data: can we learn from mismatch?', *Water Resources Research*, Vol. 55, No. 2, pp.1179–1195, doi: 10.1029/2018WR023333.
- Sun, Z., Long, D., Yang, W., Li, X. and Pan, Y. (2020a) 'Reconstruction of GRACE data on changes in total water storage over the global land surface and 60 basins', *Water Resources Research*, Vol. 56, No. 4, e2019WR026250, doi: 10.1029/2019WR026250.
- Swenson, S., Chambers, D. and Wahr, J. (2008) 'Estimating geocenter variations from a combination of GRACE and ocean model output', *Journal of Geophysical Research: Solid Earth*, Vol. 113, No. 8, pp.1–12, doi: 10.1029/2007JB005338.
- Szabó, V. and Marjańska, D. (2020) 'Accuracy analysis of gravity field changes from GRACE RL06 and RL05 data compared to in situ gravimetric measurements in the context of choosing optimal filtering type', *Artificial Satellites: Journal of Planetary Geodesy*, Vol. 55, No. 3, pp.100–117, doi: 10.2478/arsa-2020-0008.
- Tapley, B.D., Bettadpur, S., Watkins, M. and Reigber, C. (2004) 'The gravity recovery and climate experiment: mission overview and early results', *Geophysical Research Letters*, Vol. 31, No. 9, doi: 10.1029/2004GL019920.
- The World Bank [online] <https://www.worldbank.org/en/home> (accessed 16 August 2021).
- Vaniček P. (1971) 'Further development and properties of the spectral analysis by least-squares', *Astrophysics and Space Science*, Vol. 12, No. 1, pp.10–33, doi: 10.1007/BF00656134.
- Vaniček, P. (1969) 'Approximate spectral analysis by least-squares fit', *Astrophysics and Space Science*, Vol. 4, No. 4, pp.387–391, doi: 10.1007/BF00651344.
- Wahr, J., Molenaar, M. and Bryan, F. (1998) 'Time variability of the Earth's gravity field: hydrological and oceanic effects and their possible detection using GRACE', *Journal of Geophysical Research: Solid Earth*, Vol. 103, No. B12, pp.30205–30229.

SIMILARITIES AND DIFFERENCES IN THE EARTH'S WATER VARIATIONS SIGNAL PROVIDED BY GRACE AND AMSR-E OBSERVATIONS USING MAXIMUM COVARIANCE ANALYSIS AT VARIOUS LAND COVER DATA BACKGROUNDS

Viktor SZABÓ, Katarzyna OSIŃSKA-SKOTAK

Warsaw University of Technology, Faculty of Geodesy and Cartography,
Warsaw, Poland

e-mails: viktor.szabo.dokt@pw.edu.pl, katarzyna.osinska-skotak@pw.edu.pl

ABSTRACT. The study presents a compatibility analysis of gravimetric observations with passive microwave observations. Monitoring the variability of soil water content is one of the essential issues in climate-related research. Total water storage changes (ΔTWS) observed by Gravity Recovery and Climate Experiment (GRACE), enables the creation of many applications in hydrological monitoring. Soil moisture (SM) is a critical variable in hydrological studies. Advanced Microwave Scanning Radiometer (AMSR-E) satellite products provided unique observations on this variable in near-daily time resolutions. The study used maximum covariance analysis (MCA) to extract principal components for ΔTWS and SM signals. The analysis was carried out for the global area, dividing the discussion into individual continents. The amplitudes of gravimetric and microwave signals were computed via the complex empirical orthogonal function (EOF) and the complex conjugate EOF* to determine the regions for detailed comparison. Similarities and differences in signal convergence results were compared with land cover data describing soil conditions, vegetation cover, urbanization status, and cultivated land. Convergence was determined using Pearson correlation coefficients and cross-correlation. In order to compare ΔTWS and SM in individual seasons, ΔTWS observations were normalized. Results show that naturally forested areas and large open spaces used for agriculture support the compatibility between GRACE and AMSRE observations and are characterized by a good Pearson correlation coefficient >0.8 . Subpolar regions with permafrost present constraints for AMSR-E observations and have little convergence with GRACE observations.

Keywords: GRACE, AMSR-E, total water storage anomalies, soil moisture, remote sensors

1. INTRODUCTION

Soil moisture (SM) is a critical hydrologic state variable of the land that crosses the interfaces of several disciplines, of significant importance for numerous applications for meteorology, hydrology, climatology, and ecology (Robinson et al., 2008). Small changes in gravity measured from space also deduced water mass fluctuations. Launched in March 2002 twin-satellite system Gravity Recovery and Climate Experiment (GRACE) (Tapley et al., 2004b) and GRACE Follow-On (GRACE-FO) (Flechtner et al., 2016) provided unique information regarding gravity changes caused by the mass transport over the Earth's surface. Changes in total water storage



(Δ TWS) (Wahr et al., 1998) show the Earth's mass change on a near-monthly timescale. The derivative of the TWS signal is TWS anomaly (TWSA), understood as a combined monthly averaged water storage change by removing the long-term average divided by standard deviation. TWSA corresponds to the sum of all above and below surface water storage, including SM, canopy water, lakes, rivers, and groundwater. The importance of SM and Δ TWS for understanding the Earth's water cycle, and the factors affecting it over the years, has been considered in many studies individually.

The influence of estimating spatial and temporal variations of SM on climate changes was described in multiple studies (Betts et al., 1994, Engman, 1992, Entekhabi et al., 1994, Fast and McCorcle, 1991, Jackson et al., 1987, Petropoulos et al., 2014, Saha, 1995, Topp et al., 1980). Spatial and temporal variability of water was well documented in previous work for SM (Crow et al., 2012, Famiglietti et al., 2008, Vereecken et al., 2014) and Δ TWS (Landerer and Swenson, 2012, Tapley et al., 2004a, Zhao et al., 2017). From a hydrological point of view, analysis of spatiotemporal patterns of SM and Δ TWS observations is essential to understanding their behavior. In literature, existing methods describe variability only in the spatial domain (Haining et al., 2010, Khaki et al., 2017) or only in the temporal domain, based on time series analysis (Fu, 2011, Sprott and Sprott, 2003, Vishwakarma et al., 2021). Several methods can be found in the literature that analyzes Δ TWS and SM space and time domains together such as temporal stability analysis (TSA) (Martínez-Fernández and Ceballos, 2005, Wang et al., 2018), triple collocation (TC) (Crow et al., 2015, Gruber et al., 2017, Hasan and Tarhule, 2021, Yin and Park, 2021), and empirical orthogonal functions (EOFs) (Eom et al., 2017, Lei et al., 2012, Navarra and Simoncini, 2010, Schrama et al., 2007, Yoo and Kim, 2004). Whether the analysis is temporal or spatiotemporal, researchers in previous work have indicated the importance of SM as a component of the Δ TWS signal.

Water content in near-surface soil layers is a significant component of the Δ TWS signal observed by the GRACE mission. There have been many significant studies examining the relationship between SM and Δ TWS. A joint comparison of the remote sensing retrieval products' metric entropy and fluctuation complexity was considered in (Kumar et al., 2018). The satellite products of Advanced Microwave Scanning Radiometer (AMSR-E), Advanced Scatterometer (ASCAT), Soil Moisture and Ocean Salinity (SMOS), and Advanced Microwave Scanning Radiometer 2 (AMSR2) show significant noise (high entropy, low complexity), except Soil Moisture Active Passive (SMAP) is slightly noisy and more informative. The correlation greater than 0.7 between TWSA and SM data was shown in previous work (Abelen and Seitz, 2013, Crow et al., 2017, Swenson et al., 2008b). Expanding the shallow groundwater variation under the SM root zone is an essential issue in scientific research. Since using microwave satellites may be a possible way to isolate groundwater storage (GWS) variations from the GRACE signal (Frappart and Ramillien, 2018, Yeh et al., 2006), a significant area of research is the possibility of using microwave observations to determine SM.

Microwave remote sensing observations have been applied for the determination of SM (Babaeian et al., 2019). Active and passive microwave remote sensing provides an observation of SM at global and regional scales (Bartalis et al., 2007, Chen et al., 2018, Jackson et al., 2010, Kerr et al., 2016, Koike et al., 2004, Ulaby, 1982, Vinnikov et al., 1999, Wagner et al., 2013). It helps in much scientific research in hydrology and climate studies and gives an opportunity to understand environmental changes (Njoku and Entekhabi, 1996). GRACE Δ TWS and remote sensing microwave SM observations have recently been used to improve SM and GWS simulations (Tangdamrongsub et al., 2022, Tian et al., 2017).

One of the essential microwave sensors providing SM data was the AMSR-E mission. Owing to the long joint period in orbit during the operation of GRACE and AMSR-E missions, numerous previous studies have considered comparing SM from AMSR-E and Δ TWS signals from these sensors. Comparisons between the AMSR-E surface wetness index (ASWI) and the GRACE drought severity index (DSI) were shown in the previous work (Du et al., 2019). The indicated comparisons showed robust correlations in regions in the United States (R higher than 0.7 for 29 percent of the area) during the summer months (June–August) from 2002 to 2017 for regions where a semiannual temporal lag between fast surface water changes and the slower GWST was considered. The study explores multivariate data assimilation (DA) using synthetic Δ TWS from GRACE and synthetic AMSR-E passive microwave brightness temperature spectral differences (dTb) in case estimation of snow water equivalent (SWE) over snow-covered terrain was presented by Wang et al. (2021) and Wang and Forman (2020). In a previous study (Seo et al., 2010), the authors propose methods to estimate solid precipitation accumulation in winter in the northern Arctic region. Based on the GRACE and AMSR-E, winter season solid precipitation accumulation was estimated. In the second step, estimated values were compared with the traditional estimations from the Global Precipitation Climatology Project (GPCP) and Climate Prediction Center’s Merged Analysis of Precipitation (CMAP). Correlation, time shift, and principal component analyses of SM from the WaterGAP Global Hydrology Model (WGHM) and the satellite sensors AMSR-E and ASCAT to total water storage variations from the satellite gravity mission GRACE in the area of the La Plata Basin in South America were provided by Abelen et al. (2015). Regional and global variations in SM from satellite sensor AMSR-E and GRACE was also considered in Abelen et al. (2011). Global Land Data Assimilation System (GLDAS) (Rodell et al., 2004) product was used to evaluate AMSR-E observations over central Tibetan Plateau (Chen et al., 2013). To effectively catch drought disasters in the Guangdong province of southern China in 2004–2005, 2007, and 2009 SM from AMSR-E was used (Chen et al., 2012). The highest SM variability in the surface soil layer can be observed because of meteorological and environmental interactions such as precipitation, temperature changes, porosity, topography, vegetation processes, and human factors.

Although many studies have been performed on evaluating extreme hydrological events using GRACE and AMSR-E, there is a gap in the published literature concerning Δ TWS and SM signal convergence considering land cover data described soil conditions, vegetation cover, urbanization status, and cultivated land. Since the information collected by gravimetric sensors has a lower temporal frequency and spatial resolution than microwave measurements, it is crucial to investigate the convergence of these signals. The key question posed in the article is: is it possible to use the information contained by sensors characterized by higher noise and signal variance, such as AMSR-E, in the global analysis of Δ TWS variability from GRACE satellites? In work, it was decided to present the similarities and differences in the Earth’s water resource measurements. This article analyzes the spatiotemporal variations of SM and Δ TWS in the context of the similarity pattern comparison. The study used maximum covariance analysis (MCA) to extract principal components for Δ TWS and SM signals.

2. DATA AND METHODS

2.1. Data

GRACE data is available at <https://podaac-tools.jpl.nasa.gov/> (accessed on 01.06.2022) distributed by the Center for Space Research (CSR). The spatial resolution of the GRACE data included in the study is approximately 300 km x 300 km. Surface and subsurface mass change data are based on the RL06 standards (Dahle et al., 2013) at the L2

data processing level. Processing GRACE data included replaced coefficient C_{20} representing gravimetric flattening of the Earth (Swenson et al., 2008a) by Satellite Laser Ranging (SLR) observation (Cheng and Tapley, 2004) and filtered out the correlated error (Swenson and Wahr, 2006) using a modified de-correlation filter (Chen et al., 2007). Processing GRACE data also included excluding the static part of the gravity field using GGM05C model (Ries et al., 2016). During processing GRACE data the degree-1 coefficients (Geocenter) are estimated using the methods from Sun et al. (2016) and Swenson et al. (2008b). A glacial isostatic adjustment (GIA) correction has been applied based on the ICE6G-D model from Peltier et al. (2018).

The Advanced Microwave Scanning Radiometer for the Earth Observing System is a passive multiband sensor of NASA's Earth Observing System Aqua satellite. AMSR-E uses the X-band and C-band to measure the water cycle and SM content retrievals corresponding to the depth of (2.5–3.75cm) and (3.75–7.5cm), respectively. Owing to the fact that radio frequency interference (RFI) in the C-band (6.9 and 10.7 GHz), the X-band has been extensively used for SM retrieval (Njoku et al., 2005). AMSR-E dataset is available as daily files at <https://disc.gsfc.nasa.gov/> (accessed on 01.06.2022). AMSR-E/Aqua surface SM ascending V002 is a Level 3 (gridded) data set with a daily frequency and spatial resolution of about 25 km by 25 km. Land surface SM measurements is derived from passive microwave remote sensing data using the Land Parameter Retrieval Model (LPRM). The LPRM is based on a forward radiative transfer model to retrieve surface SM and vegetation optical depth. The dataset contains data from May 2002 to December 2011. AMSR-E on the NASA EOS Aqua satellite discontinued producing data in October 2011 due to an issue with the rotation of its antenna (van der Vliet et al., 2020). Only descending tracks were used because of the much better stability of nighttime soil, canopy, and air temperatures in this study (De Jeu et al., 2008, Draper et al., 2009, Liu et al., 2012, 2011, Owe et al., 2001).

The intersection of the GRACE and AMSR-E sensors datasets was selected for analysis. The time range of the selected data for this study was chosen to cover the maximum part intersection of existing GRACE and AMSR-E datasets. The dataset in the analysis contains data from 2002 to 2012 from both missions.

2.2. Methodology

Data preparation involved averaging with moving window data collected by the AMSR-E sensor over the GRACE epochs. As the compared sensors have different spatial resolutions, the data from AMSR-E were linearly interpolated on the GRACE resolution. The values for ΔTWS observed by GRACE and AMSR-E have different amplitudes. To be able to compare these results to each other, it was decided to normalize data for each season and then compare the normalized values for given seasons to minimize the effects of seasonality. Volumetric soil water content collected by AMSR-E sensor is the volume of water per unit volume of soil [m_{water}^3/m_{soil}^3] (Njoku et al., 2003). Volumetric water content (VSM) can be expressed as a ratio, percentage, or depth of water per soil (assuming a unit surface area). As the VSM data from ARMS-E were already presented as percentages, normalization was provided only at ΔTWS from GRACE. Since results of retrieving global surface SM from GRACE depend on used SM extreme values, the authors of Sadeghi et al. (2020) proposed used extreme values from overlapping SMAP and GRACE timelines from 2015 to 2017. This research used maximum and minimum values from the overlapping periods of GRACE and AMSR-E from 2002 to 2011. Normalization was performed according to the following equation:

$$TWS_{norm} = \frac{TWS - TWS_{min}}{TWS_{max} - TWS_{min}} \quad (1)$$

To reveal the similarities and differences between the values, both sensor signals were grouped for the winter, spring, summer, and autumn months. Moreover, a complementary correlation analysis was performed to assess the level of agreement between different data sources:

$$corr_{(tws),(sm)} = \frac{\sum_{i=1}^n (TWS_i - \mu_{tws})(SM_i - \mu_{sm})}{\sqrt{\sum_{i=1}^n (TWS_i - \mu_{tws})^2 (SM_i - \mu_{sm})^2}} \quad (2)$$

where μ is the mean value, and σ its standard deviation. However, some phase shifts are observed between the signals in the selected values delivered by analyzed sensors. Therefore, the analysis of signal similarity was completed with the normalized cross-correlation ($xcorr$) coefficients:

$$xcorr_{tws(t),sm(t+\tau)} = \frac{E[(TWS_t - \mu_{tws})(SM_{t+\tau} - \mu_{sm})]}{\sigma_{tws}\sigma_{sm}} \quad (3)$$

where E is the expected value of the given expression and τ is the time shift. In this case, a maximum 6 months interval of possible lags between the examined time series was determined. Anomalies for SM were also determined to indicate the similarities and differences with TWSA resulting from extreme environmental changes. TWSA and SM anomalies (SMA) were calculated by the following equations:

$$SMA_{(t)} = \frac{SM_{(t)} - \mu_{sm}}{\sigma_{sm}} \quad (4)$$

$$TWSA_{(t)} = \frac{TWS_{(t)} - \mu_{tws}}{\sigma_{tws}} \quad (5)$$

Intense spatial averaging filters with a high radius of smoothing kernel can cause signal loss, known as "leakage error" (Longuevergne et al., 2010, Swenson and Wahr, 2002). Filtering decreases the spatial resolution of the GRACE observation, making it challenging to identify the mass water signal of the main stem. The EOF analysis is a method for GRACE data to separate signals from signal noise. It is beneficial in cases such as problems with loss of geophysical signal with diminishing spatial resolution during filtration (Wouters and Schrama, 2007). The use of this method is justified in the case of comparison of microwave data with higher spatial resolution and greater time frequency of measurements than gravimetric satellite measurements. Concerning the EOF's of standard MCA (Rieger et al., 2021), the spatial amplitude (As) provides a means to understand which regions contribute the most to the given mode. The spatial amplitude is easily computed via the complex EOF and the complex conjugate EOF*:

$$As = \sqrt[2]{EOF \times EOF^*} \in \mathbb{C} \quad (6)$$

We can determine exactly how the individual regions are dynamically linked to each other. Phase shifts between these two cases are signals that can be combined into one mode with standard MCA by the following equation:

$$\theta = \tan\left(\frac{\Re(EOF)}{\Im(EOF)}\right)^{-1} \quad (7)$$

3. RESULTS

The surface soil layer commonly shows the most considerable SM variability due to the relations with meteorological, environmental, and anthropogenic factors such as porosity, topography, vegetation, precipitation, and temperature decreasing with depth. To analyze

land cover conditions, the Harmonized World Soil Database was used (Fischer et al., 2008) from <https://www.fao.org/soils-portal/data-hub/> (accessed on 01.06.2022). Land cover data contain datasets based on an iterative calculation procedure to estimate land cover class weights. It was consistent with combined Food and Agriculture Organization (FAO) land statistics and spatial land cover characteristics. Data was collected from remote sensing data, allowing interpretation and classification of land cover shares in 5' by 5' latitude/longitude grid cells. The class weights used in the study determine the presence of arable land and forests for each land cover class. As the water content strongly depends on the soil porosity, the analysis included classes presenting soil conditions in terms of oxygen content.




Figure 1. Land cover data of forest land (a), oxygen availability to roots (b), total cultivated land (c), and share of build-up land (d) based on Harmonized World Soil Database

Drainage characteristics of soils broadly define oxygen availability in soils. The determination of soil drainage classes is based on procedures developed at FAO. These procedures consider soil type, texture, terrain slope, and phases with mean proportion of water, air, and solids in soil. This publication contains characteristics of forest land, oxygen availability to roots, total cultivated land, and share of build-up land in Figure 1.




Figure 2. Seasonal patterns of ΔTWS (a), SM from band X (b), and SM from band C (c) grouped by month over time




Figure 3. Average SM from AMSR-E and Δ TWS from GRACE grouped by latitude (a) and longitude (b)

The SM and Δ TWS variables are characterized by high variability over time. The main components are related to seasonal factors included and the occurrence of dry and rainy seasons. This decline over the years is presented in Figure 2. The figure clearly shows the negative trend of Δ TWS value over the years. There are no similarities between the averaged SM and Δ TWS observations for a given month. Since the cyclic signal can be reset by cyclical phenomena occurring in a given area, the article presents averaged anomalies concerning time and latitude.

In order to characterize the values collected by gravimetric and microwave sensors, the averaged values of the observation epochs in the years 2002–2011 were determined concerning the latitude and longitude, respectively, as shown in Figure 3. Mean anomalies and standard deviation of anomalies in time over the latitude are presented in Figure 4. Figure 4 a) c) e) show an increase in the average values of TWSA and SMA in 2009–2011 for latitudes 0–20°S with a slight standard deviation for these latitudes in the given years. Both sensors picked up the same anomaly in these areas. Time series analyses in this area can be characterized by high convergence. For latitudes 20–40°N, we observe a significant TWSA anomaly that was not captured by the AMSR-E sensors. In the years 2003–2005, we observed a significant standard deviation of anomalies, which indicates a large scatter of observations and substantial variability, which was not captured when determining the average SMA values.




Figure 4. GRACE (a,b) and AMSR-E (c,d,e,f) average anomaly (a,c,e) and standard deviation (b,d,f) grouped by latitude over time

As the data on the water content in the ground shows the cycle of seasonal changes in the groundwater level, the average values were compared separately for each season of the year. The analysis was divided into the C and X bands for the SM observation. After normalizations of ΔTWS , ΔTWS and SM signals were grouped for the winter, spring, summer, and autumn seasons. Where winter months are marked as December, January, February (DJF), spring as March, April, May (MAM), summer as June, July, August (JJA), and autumn as September, October, and November (SON).




Figure 5. GRACE Δ TWS (a,d,g,j) and AMSR-E band C (b,e,h,k) and band X (c,f,i,l) SM averaged and normalized values grouped by seasons DJF (a,b,c), MAM (g,h,i), JJA (j,k,l) and SON (j,k,l)




Figure 6. Pearson correlation coefficient between SM from band X and C from AMSR-E (a), Δ TWS from GRACE and SM from band C from AMSR-E (b), Δ TWS from GRACE and SM from band X from AMSR-E (c)

Data from the C- and X-ranges are very similar. However, they are visible in the saturation of the SM parameter. In Figure 5, higher values of VSM in the areas of Amazonia can be noticed for the C- range and the latitude of 60–70 degrees. When comparing the percentages of GRACE and AMSR-E, there are apparent differences. Some of them may be due to data noise in GRACE. Theoretically, all observations from the Sahara area should be close to zero due to the near-zero water content in that area. However, variations in the water content around Lake Chad are observed (Boy et al., 2012), which partially explain this effect. More similarities can be seen between the C-band and the GRACE data, especially in the equatorial regions.

Often long-term microwave SM datasets, such as the Climate Change Initiative (CCI), based

on C- and X-band observations, are typically masked over densely vegetated areas due to the soil signal's strong attenuation by the vegetation signal canopy (Dorigo et al., 2011, Liu et al., 2011). It is worth emphasizing here that the X-band penetrates only the surface layer, the C-band a bit deeper, into with highly dense vegetation. Both bands cannot penetrate the soil in some cases (El Hajj et al., 2018). Pearson's correlation coefficient for the tested signals is presented in Figure 6.

Significant values of humidity in the X- and C-bands and low coefficients of correlation with GRACE data observed in the northern regions of the globe, are strongly related to the permafrost region. Data from this area deviates significantly in quality from other observations. No reduced correlations can be seen in forest areas during the comparison of the water content obtained from gravimetric and microwave sensors. The central part of Europe and the eastern regions of China are mainly urbanized areas. There we observe a negative correlation between GRACE and AMSR-E sensors. The anthropogenic factor related to the urbanization of space strongly influences the quality of observation (Ahmed et al., 2014, Chen et al., 2019, Wang et al., 2017). A high rate of urbanization also characterizes the Indian subcontinent. Moreover, over 60% of the area is arable land, which, due to the large number of people living in the region, is necessary to produce the right amount of food. Owing to the large open area and the lack of limitations in oxygen availability in the root zones, we can observe a significant amplitude of the SM signal. Phase compliance contributes to a high correlation in this area despite the progressive urbanization of the area, in particular in the X-band. The cultivated areas worldwide showed highly coherent GRACE and AMSR-E signals for GRACE and AMSR-E observations. The open areas do not have barriers or limitations for rainfall, which allows water to penetrate the root zone. The only exception is the eastern part of Europe, for which the overlapping of urbanization factors and soil constraints on oxygen content, and thus lower soil porosity, slows down water penetration into the soil. This causes a phase shift for the observed signals manifested by the negative correlation coefficient in this area.

EOF method is effective due to its capacity to find spatial correlation in spatiotemporal data. ΔTWS retrieved from the GRACE and SM retrieved from AMSR-E missions are decomposed using the EOF method to extract the signal, mainly describing the river discharge along the main gravity stream. Before determining the EOF, the linear trend was removed from the observations to eliminate the bias. Applying orthogonal decomposition MCA to geophysical datasets permits extracting common dominant patterns between two variables. Regions with the same color are in phase, that means their time series correlate with each other, while regions whose color is different are anticorrelated as shown in Figure 8 and Figure 9.




Figure 7. Dominant spatial pattern of water variability presented by decomposition of signal using EOF for Δ TWS from GRACE (a,d,g) and SM from AMSR-E (b,c,e,f,h,j). The first spatial pattern (EOF1) (a,b,c), the second spatial pattern (EOF2) (d,e,f), and the third spatial pattern (EOF3) (g,h,j)




Figure 8. EOF signal amplitude for Δ TWS form GRACE (a), SM from band X from AMSR-E (b), and SM from band C from AMSR-E (c)




Figure 9. EOF signal phase shift for Δ TWS form GRACE (a), SM from band X from AMSR-E (b), and SM from band C from AMSR-E (c)

4. DISCUSSION

The preservation of the flow of subsurface waters is a significant regional issue, depending on the climate determining the amount of rainwater, the topography, the arrangement of permeable layers, and the presence of river sources. In this part of the article, regional studies were carried out for selected river basins with the most significant area by selecting cases for all continents. Regional analyses appear in earlier articles by Vishwakarma et al. (2021), where time series analysis was carried out for major river basins. In this article, scientists capture significant dips and identify constraints due to too short an observation period using the trend to variability ratio (TVR) metric. This section focuses on the reasons for similarities and differences in gravimetric and microwave signals in selected areas. The observations provided by the GRACE mission are characterized by a significantly lower spatial resolution than microwave observations. The application of grouping to the studied signals within rivers allows for finding patterns resulting from minimizing errors resulting from noise or artifacts of the filtration process. For each continent, a set of rivers with the largest area and different land cover features and different latitudes was selected, thus eliminating bias in the dataset sample. For selected river basins, Pearson's correlation coefficients and cross-correlation, taking into account the phase shift calculated according to formula (2) and presented in Figure 10 and Figure 11, were determined.




Figure 10. Pearson correlation over selected rivers basin between ΔTWS from GRACE and SM from band X from AMSR-E (a) and ΔTWS from GRACE and SM from band C from AMSR-E (b)





Figure 11. Cross-correlation over selected rivers basin between ΔTWS from GRACE and SM from band X from AMSR-E (a) and ΔTWS from GRACE and SM from band C from AMSR-E (b)

Examples of ΔTWS and SM time series and TWSA and SMA anomalies are shown in Figure 12.






Figure 12. River basin time series containing Δ TWS and SM (a,c,e,g,i,k,m,o,q,s,u,w), TWSA and SMA (b,d,f,h,j,l,n,p,r,t,v,x) for European (a,b,c,d), North America (e,f,g,h), South America (i,j,k,l), Asian (m,n,o,p), African (q,r,s,t,w,x), and Australian (u,v) rivers

4.1. Europe

The analysis shows that the size of the river basin is not directly related to the differences in GRACE and AMSR-E signals. Large European rivers, such as the Danube and the Vistula, show the mutual shift of hydrological signals for gravimetric and microwave remote sensors as can be seen in Figure 12 a), c). There is a more significant variance in the signal for observations from the X- and C-bands than in GRACE observations. Therefore, the determined anomalies are characterized by high noise for these ranges. Similar to the analysis performed in Kuczynska-Siehién et al. (2019), the GRACE and AMSR-E sensors pick up an anomaly related to the 2010 hydrological flood. However, contrary to the cited article, the SM determined from AMSR-E indicates the occurrence of anomalies in the years 2007–2009, which is not recorded in the GLDAS models. The snowfall in these regions during the months of DJF indicates a lower moisture content in the soil, while GRACE sensors capture the mass contained in the snow equivalent. This is explained by the method used to process AMSR-E data. Under frozen surface conditions, the dielectric properties of the water change dramatically. Therefore, the method assigns all pixels where the surface temperature is observed to be at or below 273 K with an appropriate data flag (Holmes et al., 2009).

4.2. Africa

The Nile basin shows a very high agreement between GRACE and AMSR-E signals in both X- and C-bands for the Δ TWS and SM values and their anomalies. The Pearson correlation coefficient between these variables is greater than 0.8 for this region. The lack of soil constraints and little human intervention in the form of agricultural or urban activities contribute to the consistency of observations (Gossel et al., 2004). The percentage of arable land with additional irrigation is less than 5% (Villholth, 2013). In the case of the Nile, a significant factor influencing the changes in Δ TWS is surface runoff. The weather extremes and climatic variances observed over the years using gravimetric observations indicate the high sensitivity of these sensors to

extreme phenomena such as droughts (Scanlon et al., 2022, Seka et al., 2022a,b). The GRACE and AMSR-E sensors catch the 2005 and 2010 drought anomalies, shown in Figure 12 t). Similar results were also described by Seka et al. (2022b) using meteorological drought indicators and a water storage deficit index (WSDI) occurring at the source of the Nile in the Turkana, Victoria, and Tanganyika lakes.

The Congo River basin, known as Zaire, is over 60% covered by tropical forests. Crops account for only 10% of the area. The correlation of gravimetric and microwave signals is lower than at the same latitude for the Amazon basin. In this case, data collected by the AMSR-E mission detects two seasonal signal peaks, while GRACE usually has only one, as presented in Figure 12 q), r). The X-band observations for shallow soil layers do not detect a split between longer and shorter rainfall. At the same time, the C-band distinguishes subseasonal changes more like the GRACE observations. Despite the lack of soil constraints, such a large area affected by changes in precipitation caused by the movement of circulation cells poses a challenge for scientists in interpreting Δ TWS and SM observations.

The Zambezi River basin maintained an above-average consistency between GRACE and AMSR-E signals in both X- and C-bands for the Δ TWS and SM values and their anomalies also described in Thomas et al. (2014) and Hassan and Jin (2016). Similar to Thomas et al. (2014), a water deficit was observed in the area Zambezi River basin due to a hydrological drought event in April 2005. For the Zambezi and Zaire river basins, the highest amplitudes of Δ TWS and SM signals on the African continent can be observed. It can therefore be concluded, similarly to the publication of Hassan and Jin (2016), that the Δ TWS in these regions is dominated mainly by precipitation. Despite the relatively poorly urbanized area, the most important anthropogenic factors include that the Zambezi River is used to produce electricity for southern Africa. In the middle stretch of the river, there is a large artificial water reservoir called Kariba. Incremental storage of a large mass of water favors capturing this effect by GRACE sensors with a minor time frequency. Large uncovered agricultural areas and lack of factors contributing to noise in microwave observations contribute to a significant convergence of results with gravimetric sensors.

4.3. North America

The large rivers of North America have different results for the studied similarity between gravimetric and microwave observations. The Mackenzie River basin has its source in Great Slave Lake. Located in the north of Canada in subpolar regions, the source is closely related to the snow equivalent variances visible in the GRACE observations but not included in the X- and C-bands. A similar situation will be seen in the subpolar regions of the Ob River. This result is visible in small correlations and low aggregation of Δ TWS and SM signals and their anomalies.

The Mississippi River basin has the opposite statistics compared to the Mackenzie River described previously. The high agreement of Δ TWS and SM observations, shown by the cross-correlation coefficient > 0.7 , is due to the large area of agricultural crops. No limitations for soil conditions, and $<10\%$ afforestation of the area does not retain water in the vegetation and allows free seepage to groundwater. The main components of EOF3 show similar signal strength in terms of area. Observations in the X-range have a slightly more substantial phase shift than observations from the C microwave band. However, the difference is not significant in the context of the examined similarity to gravimetric observations. The high compatibility of TWSA and SMA allows both sensors to quickly monitor and predict natural disasters caused by droughts or floods (Foroumandi et al., 2022).

4.4. South America

The Amazon basin, well described in the literature previously by Chen et al. (2009), Cui et al. (2020, 2022), Eom et al. (2017) and Wu et al. (2022), is exceptionally consistent for GRACE and AMSR-E signals despite being mostly forested. Observations in the X-band captured the 2004 anomaly, which is not visible in the C-band observations. Both bands indicated an anomaly in 2009 resulting from the exceptional flood in this area (Chen et al., 2010b) and droughts in 2010–2012 (Nie et al., 2015). As in the two previously mentioned publications, extreme hydrological phenomena from 2009 to 2012 were captured by the GRACE and AMSR-E sensors in Figure 12 j). A large area and one of the largest amplitudes of water fluctuations resulting from tropical rains occurring at equatorial latitudes cause, despite minor soil limitations, the studied signals to be characterized by considerable convergence.

The La Plata basin region is characterized by a significant anomaly in the GRACE and AMSR-E observations in Figure 4. Extremes occurring in this area require special attention during interpretation (Abelen et al., 2015, Chen et al., 2010a). The low topographic complexity facilitates penetration of the microwave signal. Secondly, a higher value of EOF3 shown in Figure 7 in the X-band AMSR-E indicates the occurrence of phenomena that in the literature can be found as the flood of winter 2009/2010. It was correlated with the occurrence of the El Niño effect and the droughts occurring in 2009. The analysis of the main components indicates that extreme hydrological phenomena have a significant effect both in gravimetric and microwave data. However, due to the differentiation in the La Plata river basin, these phenomena are characterized by a phase shift.

4.5. Asia

The Amur is the tenth longest river in the world, forming the border between the Russian Far East and Northeast China. From the north of the basin, the area covers permafrost and is covered with the boreal forest. The southern part of the area is intensively cultivated and distorted by human activity. As can be seen in Figure 11, the cross-correlation coefficient is at the level of 0.3, which proves the extremely poor compatibility of the Δ TWS and SM signals. This is also confirmed in Figure 12 m), n) presenting the time series for this area. Extreme droughts and wildfires in 2008 described previously in Semenov et al. (2017) are reflected in GRACE observations in this research, represented by an anomaly in this period, which is entirely absent in microwave observations.

The Ganges and Brahmaputra valley is intensively used for agriculture and densely populated area near the Himalayas. The monsoons in this area have become a permanent part of the landscape of the local population. Δ TWS observations in that area were previously described by Felfelani et al. (2017), Forootan et al. (2016) and Papa et al. (2015). Figure 12 o) shows a good agreement between the Δ TWS and SM signals. Cross-correlation over this basin is at a level of 0.75. However, Figure 12 p) shows the discrepancy between TWSA and SMA characterized by the opposite trend in the 2006–2012 period. A similar difference was noted in (Felfelani et al., 2017), described as a significant divergence between the SM natural and GRACE Δ TWS trend lines. As in the case of the Zaire River, the observations provided by the AMSR-E mission capture two annual waves and only one primary wave during GRACE. In this case, the differences between the X- and C-bands are smaller than in the case of the Congo Basin. Strong amplitudes of GRACE and AMSR-E signals, especially in the X-range, presented in Figure 8 a), b) indicate the intensity of SM changes in shallow layers for the largest river delta in the world.

4.6. Australia

The Murray-Darling basin is a large geographic area in the interior of south-eastern Australia with intensive farmland use around Adelaide. The area is characterized by one of the best TWSA and SMA signal correspondences observed in Figure 12 v). The decreasing trend of water content in the soil in this area was described by Heimhuber et al. (2019), Tregoning et al. (2012) and Yang et al. (2014). We see considerable agreement in the detected anomaly in 2010-2011 for gravimetric and microwave sensors. Similar conclusions as in the article by Heimhuber et al. (2019) can be obtained regarding the interpretation of the results from the period 2010–2012. La Nina Floods can be observed in higher TWSA and SMA in Figure 12 v). Unlike previous works, ASMR-E sensors did not show decreasing trend related to the 2000–2009 Millennium Drought. This is partly explained by the aggregation of data over a large river basin area and the different intensification of phenomena in the northern and southern parts of the river basin. Observations in the C-band compared to GRACE are similar in phase. Figure 9 shows a more significant shift in the observations of the X-band for its main components, which explains the shallow penetration into the soil layers for this band. However, the lack of significant global constraints, large open spaces, and small built-up areas create favorable conditions for the GRACE and AMSR-E satellites to detect the same groundwater characteristics and variances. The high Pearson correlation coefficient at the level of 0.8 and the cross-correlation of about 0.7 are visible in Figure 10 and Figure 11.

5. CONCLUSIONS

This article discusses the conditions under which the Δ TWS observations provided by the gravimetric GRACE mission are characterized by a greater or lesser signal convergence with the observations provided by the passive multiwavelength microwave sensors of the AMSR-E mission. The interplay of Δ TWS and SM can provide a better and high-resolution understanding of the Earth's processes related to the water cycle. The complexity of land uses processes and conditions impacts the detection and mapping of natural hazards, such as droughts or floods, observed on a global or regional scale. Understanding the limitations affecting the speed of detection of changes and consistency in the observations provided using various methods and sensors has a tangible impact on the quality of the solutions provided for the prediction of geo-hazards. The main conclusions and observations from the conducted study worth emphasizing are the mutual relationship between the use of cultivated and forested areas in the Δ TWS and SM compliance analyses. Naturally forested areas and large open spaces used for agriculture support the compatibility between GRACE and AMSR-E observations. The discussion showed a high correlation for these areas, at the same time pointing to the importance of good oxygen conditions for root zones in the soil. Existing soil constraints such as permafrost significantly eliminate the usefulness of X- and C-range microwave observations. For this reason, analyses carried out in subpolar regions using gravimetric sensors have a significant advantage. The referenced examples in the subsection for Europe indicate differences between GRACE and AMSR-E in signals leading to the conclusion of unfavorable conditions resulting from soil constraints and significant urbanization of the area. Moreover, the study opens the question of spatial data leakage caused by filtering low-resolution GRACE data. Regions with high signal variance averaged over the area of the entire river basin may cause the loss of a part of the geophysical signal, which was observed and described for the example of the Zaire River. The use of mathematical methods and a combination of signals with different spatial and temporal resolutions, for areas with appropriate conditions and no soil and urban restrictions, will be the next direction of the research.

Acknowledgments.

Data availability:

Data from the GRACE mission was collected from <https://podaac-tools.jpl.nasa.gov/> distributed by the Center for Space Research (CSR). AMSR-E dataset was downloaded as daily files from <https://disc.gsfc.nasa.gov/>. To analyze land cover conditions The Harmonized World Soil Database was used from <https://www.fao.org/soils-portal/data-hub/>.

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 article.

REFERENCES

- Abelen, S. and Seitz, F. (2013). Relating satellite gravimetry data to global soil moisture products via data harmonization and correlation analysis. *Remote Sensing of Environment*, 136:89–98.
- Abelen, S., Seitz, F., Abarca-del Rio, R., and Güntner, A. (2015). Droughts and floods in the la plata basin in soil moisture data and grace. *Remote Sensing*, 7(6):7324–7349.
- Abelen, S., Seitz, F., Schmidt, M., and Güntner, A. (2011). Analysis of regional variations in soil moisture by means of remote sensing, satellite gravimetry and hydrological modelling. *GRACE, Remote Sensing and Ground-Based Methods in Multi-Scale Hydrology, IAHS Red Book Series*, (343):9–15.
- Ahmed, M., Sultan, M., Wahr, J., and Yan, E. (2014). The use of grace data to monitor natural and anthropogenic induced variations in water availability across africa. *Earth-Science Reviews*, 136:289–300.
- Babaeian, E., Sadeghi, M., Jones, S. B., Montzka, C., Vereecken, H., and Tuller, M. (2019). Ground, proximal, and satellite remote sensing of soil moisture. *Reviews of Geophysics*, 57(2):530–616.
- Bartalis, Z., Wagner, W., Naeimi, V., Hasenauer, S., Scipal, K., Bonekamp, H., Figa, J., and Anderson, C. (2007). Initial soil moisture retrievals from the metop-a advanced scatterometer (ascat). *Geophysical Research Letters*, 34(20).
- Betts, A. K., Ball, J. H., Beljaars, A., Miller, M., and Viterbo, P. (1994). Coupling between land-surface boundary-layer parameterizations and rainfall on local and regional scales: Lessons from the wet summer of 1993. In *Fifth Symp. on Global Change Studies*, pages 174–181.
- Boy, J.-P., Hinderer, J., and de Linage, C. (2012). Retrieval of large-scale hydrological signals in africa from grace time-variable gravity fields. *Pure and applied Geophysics*, 169(8):1373–1390.
- Chen, F., Crow, W. T., Bindlish, R., Colliander, A., Burgin, M. S., Asanuma, J., and Aida, K. (2018). Global-scale evaluation of smap, smos and ascat soil moisture products using triple collocation. *Remote Sensing of Environment*, 214:1–13.
- Chen, H., Zhang, W., Nie, N., and Guo, Y. (2019). Long-term groundwater storage variations estimated in the songhua river basin by using grace products, land surface models, and in-situ observations. *Science of the Total Environment*, 649:372–387.
- Chen, J., Wilson, C., Tapley, B., Longuevergne, L., Yang, Z., and Scanlon, B. (2010a). Recent la plata basin drought conditions observed by satellite gravimetry. *Journal of Geophysical Research: Atmospheres*, 115(D22).

- Chen, J., Wilson, C., Tapley, B., Yang, Z., and Niu, G.-Y. (2009). 2005 drought event in the amazon river basin as measured by grace and estimated by climate models. *Journal of Geophysical Research: Solid Earth*, 114(B5).
- Chen, J. L., Wilson, C. R., and Tapley, B. D. (2010b). The 2009 exceptional amazon flood and interannual terrestrial water storage change observed by grace. *Water Resources Research*, 46(12).
- Chen, J. L., Wilson, C. R., Tapley, B. D., and Grand, S. (2007). Grace detects coseismic and postseismic deformation from the sumatra-andaman earthquake. *Geophysical Research Letters*, 34(13).
- Chen, X.-z., Chen, S.-s., Zhong, R.-f., Su, Y.-x., Liao, J.-s., Li, D., Han, L.-s., Li, Y., and Li, X. (2012). A semi-empirical inversion model for assessing surface soil moisture using amsr-e brightness temperatures. *Journal of hydrology*, 456:1–11.
- Chen, Y., Yang, K., Qin, J., Zhao, L., Tang, W., and Han, M. (2013). Evaluation of amsr-e retrievals and gldas simulations against observations of a soil moisture network on the central tibetan plateau. *Journal of Geophysical Research: Atmospheres*, 118(10):4466–4475.
- Cheng, M. and Tapley, B. D. (2004). Variations in the earth's oblateness during the past 28 years. *Journal of Geophysical Research: Solid Earth*, 109(B9).
- Crow, W. T., Berg, A. A., Cosh, M. H., Loew, A., Mohanty, B. P., Panciera, R., de Rosnay, P., Ryu, D., and Walker, J. P. (2012). Upscaling sparse ground-based soil moisture observations for the validation of coarse-resolution satellite soil moisture products. *Reviews of Geophysics*, 50(2).
- Crow, W. T., Han, E., Ryu, D., Hain, C. R., and Anderson, M. C. (2017). Estimating annual water storage variations in medium-scale (2000–10 000 km²) basins using microwave-based soil moisture retrievals. *Hydrology and Earth System Sciences*, 21(3):1849–1862.
- Crow, W. T., Lei, F., Hain, C., Anderson, M. C., Scott, R. L., Billesbach, D., and Arkebauer, T. (2015). Robust estimates of soil moisture and latent heat flux coupling strength obtained from triple collocation. *Geophysical Research Letters*, 42(20):8415–8423.
- Cui, L., Song, Z., Luo, Z., Zhong, B., Wang, X., and Zou, Z. (2020). Comparison of terrestrial water storage changes derived from grace/grace-fo and swarm: A case study in the amazon river basin. *Water*, 12(11):3128.
- Cui, L., Yin, M., Huang, Z., Yao, C., Wang, X., and Lin, X. (2022). The drought events over the amazon river basin from 2003 to 2020 detected by grace/grace-fo and swarm satellites. *Remote Sensing*, 14(12):2887.
- Dahle, C., Flechtner, F., Gruber, C., König, D., König, R., Michalak, G., and Neumayer, K.-H. (2013). Gfz grace level-2 processing standards document for level-2 product release 0005: revised edition, january 2013.
- De Jeu, R. A., Wagner, W., Holmes, T., Dolman, A., Van De Giesen, N., and Friesen, J. (2008). Global soil moisture patterns observed by space borne microwave radiometers and scatterometers. *Surveys in Geophysics*, 29(4):399–420.
- Dorigo, W., Wagner, W., Hohensinn, R., Hahn, S., Paulik, C., Xaver, A., Gruber, A., Drusch, M., Mecklenburg, S., van Oevelen, P., et al. (2011). The international soil moisture network: a data hosting facility for global in situ soil moisture measurements. *Hydrology and Earth System Sciences*, 15(5):1675–1698.
- Draper, C. S., Walker, J. P., Steinle, P. J., De Jeu, R. A., and Holmes, T. R. (2009). An evaluation

of amsr-e derived soil moisture over australia. *Remote Sensing of Environment*, 113(4):703–710.

Du, J., Kimball, J., Velicogna, I., Zhao, M., Jones, L., Watts, J., and Kim, Y. (2019). Multicomponent satellite assessment of drought severity in the contiguous united states from 2002 to 2017 using amsr-e and amsr2. *Water Resources Research*, 55(7):5394–5412.

El Hajj, M., Baghdadi, N., Bazzi, H., and Zribi, M. (2018). Penetration analysis of sar signals in the c and l bands for wheat, maize, and grasslands. *Remote Sensing*, 11(1):31.

Engman, E. T. (1992). Soil moisture needs in earth sciences. In *In: IGARSS'92; Proceedings of the 12th Annual International Geoscience and Remote Sensing Symposium, Houston, TX, May 26-29, 1992. Vol. 1 (A93-47551 20-43)*. Institute of Electrical and Electronics Engineers, Inc.

Entekhabi, D., Nakamura, J., and Njoku, E. (1994). Retrieval of soil moisture profile by combined remote sensing and modeling. *Passive Microwave Remote Sensing of Land-Atmosphere Interactions: [ESA/NASA International Workshop, Held at Saint Lary (France) from January 11–15, 1993]*.

Eom, J., Seo, K.-W., and Ryu, D. (2017). Estimation of amazon river discharge based on eof analysis of grace gravity data. *Remote Sensing of Environment*, 191:55–66.

Famiglietti, J. S., Ryu, D., Berg, A. A., Rodell, M., and Jackson, T. J. (2008). Field observations of soil moisture variability across scales. *Water Resources Research*, 44(1).

Fast, J. D. and McCorcle, M. D. (1991). The effect of heterogeneous soil moisture on a summer baroclinic circulation in the central united states. *Monthly weather review*, 119(9):2140–2167.

Felfelani, F., Wada, Y., Longuevergne, L., and Pokhrel, Y. N. (2017). Natural and human-induced terrestrial water storage change: A global analysis using hydrological models and grace. *Journal of Hydrology*, 553:105–118.

Fischer, G., Nachtergaele, F., Prieler, S., Van Velthuisen, H., Verelst, L., and Wiberg, D. (2008). Global agro-ecological zones assessment for agriculture (gaez 2008). *IIASA, Laxenburg, Austria and FAO, Rome, Italy*, 10.

Flechtner, F., Neumayer, K.-H., Dahle, C., Dobsław, H., Fagiolini, E., Raimondo, J.-C., and Güntner, A. (2016). What can be expected from the grace-fo laser ranging interferometer for earth science applications? In *Remote sensing and water resources*, pages 263–280. Springer.

Forootan, E., Schumacher, M., Awange, J. L., and Müller Schmied, H. (2016). Exploring the influence of precipitation extremes and human water use on total water storage (twts) changes in the ganges-brahmaputra-meghna river basin. *Water Resources Research*, 52(3):2240–2258.

Foroumandi, E., Nourani, V., Huang, J. J., and Moradkhani, H. (2022). Drought monitoring by downscaling grace-derived terrestrial water storage anomalies: a deep learning approach. *Journal of Hydrology*, page 128838.

Frappart, F. and Ramillien, G. (2018). Monitoring groundwater storage changes using the gravity recovery and climate experiment (grace) satellite mission: A review. *Remote Sensing*, 10(6):829.

Fu, T.-c. (2011). A review on time series data mining. *Engineering Applications of Artificial Intelligence*, 24(1):164–181.

Gossel, W., Ebraheem, A., and Wycisk, P. (2004). A very large scale gis-based groundwater flow model for the nubian sandstone aquifer in eastern sahara (egypt, northern sudan and eastern libya). *Hydrogeology Journal*, 12(6):698–713.

Gruber, A., Dorigo, W. A., Crow, W., and Wagner, W. (2017). Triple collocation-based merging of satellite soil moisture retrievals. *IEEE Transactions on Geoscience and Remote Sensing*,

55(12):6780–6792.

Haining, R. P., Kerry, R., and Oliver, M. A. (2010). Geography, spatial data analysis, and geostatistics: An overview. *Geographical Analysis*, 42(1):7–31.

Hasan, E. and Tarhule, A. (2021). Comparison of decadal water storage trends from common grace releases (rl05, rl06) using spatial diagnostics and a modified triple collocation approach. *Journal of Hydrology X*, 13:100108.

Hassan, A. and Jin, S. (2016). Water storage changes and balances in africa observed by grace and hydrologic models. *Geodesy and Geodynamics*, 7(1):39–49.

Heimhuber, V., Tulbure, M. G., Broich, M., Xie, Z., and Hurriyet, M. (2019). The role of grace total water storage anomalies, streamflow and rainfall in stream salinity trends across australia's murray-darling basin during and post the millennium drought. *International Journal of Applied Earth Observation and Geoinformation*, 83:101927.

Holmes, T., De Jeu, R., Owe, M., and Dolman, A. (2009). Land surface temperature from ka band (37 ghz) passive microwave observations. *Journal of Geophysical Research: Atmospheres*, 114(D4).

Jackson, T., Hawley, M., and O'Neill, P. (1987). Preplanting soil moisture using passive microwave sensors 1. *JAWRA Journal of the American Water Resources Association*, 23(1):11–19.

Jackson, T. J., Cosh, M. H., Bindlish, R., Starks, P. J., Bosch, D. D., Seyfried, M., Goodrich, D. C., Moran, M. S., and Du, J. (2010). Validation of advanced microwave scanning radiometer soil moisture products. *IEEE Transactions on Geoscience and Remote Sensing*, 48(12):4256–4272.

Kerr, Y. H., Al-Yaari, A., Rodriguez-Fernandez, N., Parrens, M., Molero, B., Leroux, D., Bircher, S., Mahmoodi, A., Mialon, A., Richaume, P., et al. (2016). Overview of smos performance in terms of global soil moisture monitoring after six years in operation. *Remote Sensing of Environment*, 180:40–63.

Khaki, M., Schumacher, M., Forootan, E., Kuhn, M., Awange, J. L., and van Dijk, A. I. (2017). Accounting for spatial correlation errors in the assimilation of grace into hydrological models through localization. *Advances in Water Resources*, 108:99–112.

Koike, T., Nakamura, Y., Kaihotsu, I., Davaa, G., Matsuura, N., Tamagawa, K., and Fujii, H. (2004). Development of an advanced microwave scanning radiometer (amsr-e) algorithm for soil moisture and vegetation water content. *Proceedings of Hydraulic Engineering*, 48:217–222.

Kuczynska-Siehien, J., Piretzidis, D., Sideris, M. G., Olszak, T., and Szabó, V. (2019). Monitoring of extreme land hydrology events in central poland using grace, land surface models and absolute gravity data. *Journal of Applied Geodesy*, 13(3):229–243.

Kumar, S. V., Dirmeyer, P. A., Peters-Lidard, C. D., Bindlish, R., and Bolten, J. (2018). Information theoretic evaluation of satellite soil moisture retrievals. *Remote sensing of environment*, 204:392–400.

Landerer, F. W. and Swenson, S. (2012). Accuracy of scaled grace terrestrial water storage estimates. *Water resources research*, 48(4).

Lei, J., Matsuo, T., Dou, X., Sutton, E., and Luan, X. (2012). Annual and semiannual variations of thermospheric density: Eof analysis of champ and grace data. *Journal of Geophysical Research: Space Physics*, 117(A1).

Liu, Y., Dorigo, W. A., Parinussa, R., de Jeu, R. A., Wagner, W., McCabe, M. F., Evans, J., and

- Van Dijk, A. (2012). Trend-preserving blending of passive and active microwave soil moisture retrievals. *Remote Sensing of Environment*, 123:280–297.
- Liu, Y. Y., Parinussa, R., Dorigo, W. A., De Jeu, R. A., Wagner, W., Van Dijk, A., McCabe, M. F., and Evans, J. (2011). Developing an improved soil moisture dataset by blending passive and active microwave satellite-based retrievals. *Hydrology and Earth System Sciences*, 15(2):425–436.
- Longuevergne, L., Scanlon, B. R., and Wilson, C. R. (2010). Grace hydrological estimates for small basins: Evaluating processing approaches on the high plains aquifer, usa. *Water Resources Research*, 46(11).
- Martínez-Fernández, J. and Ceballos, A. (2005). Mean soil moisture estimation using temporal stability analysis. *Journal of Hydrology*, 312(1-4):28–38.
- Navarra, A. and Simoncini, V. (2010). *A guide to empirical orthogonal functions for climate data analysis*. Springer Science & Business Media.
- Nie, N., Zhang, W., Guo, H., and Ishwaran, N. (2015). 2010–2012 drought and flood events in the amazon basin inferred by grace satellite observations. *Journal of Applied Remote Sensing*, 9(1):096023.
- Njoku, E. G., Ashcroft, P., Chan, T. K., and Li, L. (2005). Global survey and statistics of radio-frequency interference in amsr-e land observations. *IEEE Transactions on Geoscience and Remote Sensing*, 43(5):938–947.
- Njoku, E. G. and Entekhabi, D. (1996). Passive microwave remote sensing of soil moisture. *Journal of hydrology*, 184(1-2):101–129.
- Njoku, E. G., Jackson, T. J., Lakshmi, V., Chan, T. K., and Nghiem, S. V. (2003). Soil moisture retrieval from amsr-e. *IEEE transactions on Geoscience and remote sensing*, 41(2):215–229.
- Owe, M., de Jeu, R., and Walker, J. (2001). A methodology for surface soil moisture and vegetation optical depth retrieval using the microwave polarization difference index. *IEEE Transactions on Geoscience and Remote Sensing*, 39(8):1643–1654.
- Papa, F., Frappart, F., Malbeteau, Y., Shamsudduha, M., Vuruputur, V., Sekhar, M., Ramillien, G., Prigent, C., Aires, F., Pandey, R. K., et al. (2015). Satellite-derived surface and sub-surface water storage in the ganges–brahmaputra river basin. *Journal of Hydrology: Regional Studies*, 4:15–35.
- Peltier, W., Argus, D. F., and Drummond, R. (2018). Comment on “an assessment of the ice-6g_c (vm5a) glacial isostatic adjustment model” by purcell et al. *Journal of Geophysical Research: Solid Earth*, 123(2):2019–2028.
- Petropoulos, G. P., Ireland, G., Srivastava, P. K., and Ioannou-Katidis, P. (2014). An appraisal of the accuracy of operational soil moisture estimates from smos miras using validated in situ observations acquired in a mediterranean environment. *International Journal of Remote Sensing*, 35(13):5239–5250.
- Rieger, N., Corral, Á., Olmedo, E., and Turiel, A. (2021). Lagged teleconnections of climate variables identified via complex rotated maximum covariance analysis. *Journal of Climate*, 34(24):9861–9878.
- Ries, J., Bettadpur, S., Eanes, R., Kang, Z., Ko, U., McCullough, C., Nagel, P., Pie, N., Poole, S., Richter, T., et al. (2016). The combined gravity model ggm05c. *GFZ Data Services*.
- Robinson, D. A., Campbell, C. S., Hopmans, J. W., Hornbuckle, B. K., Jones, S. B., Knight, R.,

- Ogden, F., Selker, J., and Wendroth, O. (2008). Soil moisture measurement for ecological and hydrological watershed-scale observatories: A review. *Vadose Zone Journal*, 7(1):358–389.
- Rodell, M., Houser, P., Jambor, U., Gottschalk, J., Mitchell, K., Meng, C.-J., Arsenault, K., Cosgrove, B., Radakovich, J., Bosilovich, M., et al. (2004). The global land data assimilation system. *Bulletin of the American Meteorological society*, 85(3):381–394.
- Sadeghi, M., Gao, L., Ebtehaj, A., Wigneron, J.-P., Crow, W. T., Reager, J. T., and Warrick, A. W. (2020). Retrieving global surface soil moisture from grace satellite gravity data. *Journal of Hydrology*, 584:124717.
- Saha, S. (1995). Assessment of regional soil moisture conditions by coupling satellite sensor data with a soil-plant system heat and moisture balance model. *Remote Sensing*, 16(5):973–980.
- Scanlon, B. R., Rateb, A., Anyamba, A., Kebede, S., MacDonald, A. M., Shamsudduha, M., Small, J., Sun, A., Taylor, R. G., and Xie, H. (2022). Linkages between grace water storage, hydrologic extremes, and climate teleconnections in major african aquifers. *Environmental Research Letters*, 17(1):014046.
- Schrama, E. J., Wouters, B., and Lavallée, D. A. (2007). Signal and noise in gravity recovery and climate experiment (grace) observed surface mass variations. *Journal of Geophysical Research: Solid Earth*, 112(B8).
- Seka, A. M., Zhang, J., Prodhan, F. A., Ayele, G. T., Finsa, M. M., Sharma, T. P. P., and Melesse, A. M. (2022a). Hydrological drought impacts on water storage variations: a focus on the role of vegetation changes in the east africa region. a systematic review. *Environmental Science and Pollution Research*, pages 1–20.
- Seka, A. M., Zhang, J., Zhang, D., Ayele, E. G., Han, J., Prodhan, F. A., Zhang, G., and Liu, Q. (2022b). Hydrological drought evaluation using grace satellite-based drought index over the lake basins, east africa. *Science of The Total Environment*, 852:158425.
- Semenov, E., Sokolikhina, N., and Tatarinovich, E. (2017). Monsoon circulation over the amur river basin during catastrophic flood and extreme drought in summer. *Russian Meteorology and Hydrology*, 42(3):141–149.
- Seo, K.-W., Ryu, D., Kim, B.-M., Waliser, D. E., Tian, B., and Eom, J. (2010). Grace and amsr-e-based estimates of winter season solid precipitation accumulation in the arctic drainage region. *Journal of Geophysical Research: Atmospheres*, 115(D20).
- Sprott, J. C. and Sprott, J. C. (2003). *Chaos and time-series analysis*, volume 69. Oxford university press Oxford.
- Sun, Y., Riva, R., and Ditmar, P. (2016). Optimizing estimates of annual variations and trends in geocenter motion and j2 from a combination of grace data and geophysical models. *Journal of Geophysical Research: Solid Earth*, 121(11):8352–8370.
- Swenson, S., Chambers, D., and Wahr, J. (2008a). Estimating geocenter variations from a combination of grace and ocean model output. *Journal of Geophysical Research: Solid Earth*, 113(B8).
- Swenson, S., Famiglietti, J., Basara, J., and Wahr, J. (2008b). Estimating profile soil moisture and groundwater variations using grace and oklahoma mesonet soil moisture data. *Water Resources Research*, 44(1).
- Swenson, S. and Wahr, J. (2002). Methods for inferring regional surface-mass anomalies from gravity recovery and climate experiment (grace) measurements of time-variable gravity. *Journal*

of Geophysical Research: Solid Earth, 107(B9):ETG–3.

Swenson, S. and Wahr, J. (2006). Post-processing removal of correlated errors in grace data. *Geophysical research letters*, 33(8).

Tangdamrongsub, N., Dong, J., and Shellito, P. (2022). Assessing performances of multivariate data assimilation algorithms with smos, smap, and grace observations for improved soil moisture and groundwater analyses. *Water*, 14(4):621.

Tapley, B. D., Bettadpur, S., Ries, J. C., Thompson, P. F., and Watkins, M. M. (2004a). Grace measurements of mass variability in the earth system. *science*, 305(5683):503–505.

Tapley, B. D., Bettadpur, S., Watkins, M., and Reigber, C. (2004b). The gravity recovery and climate experiment: Mission overview and early results. *Geophysical research letters*, 31(9).

Thomas, A. C., Reager, J. T., Famiglietti, J. S., and Rodell, M. (2014). A grace-based water storage deficit approach for hydrological drought characterization. *Geophysical Research Letters*, 41(5):1537–1545.

Tian, S., Tregoning, P., Renzullo, L. J., van Dijk, A. I., Walker, J. P., Pauwels, V. R., and Allgeyer, S. (2017). Improved water balance component estimates through joint assimilation of grace water storage and smos soil moisture retrievals. *Water Resources Research*, 53(3):1820–1840.

Topp, G. C., Davis, J., and Annan, A. P. (1980). Electromagnetic determination of soil water content: Measurements in coaxial transmission lines. *Water resources research*, 16(3):574–582.

Tregoning, P., McClusky, S., Van Dijk, A., Crosbie, R., and Peña-Arancibia, J. (2012). Assessment of grace satellites for groundwater estimation in australia. *National Water Commission, Canberra*, 82.

Ulaby, F. T. (1982). Microwave remote sensing active and passive. *Rader remote sensing and surface scattering and emission theory*, pages 848–902.

van der Vliet, M., van der Schalie, R., Rodriguez-Fernandez, N., Colliander, A., de Jeu, R., Preimesberger, W., Scanlon, T., and Dorigo, W. (2020). Reconciling flagging strategies for multi-sensor satellite soil moisture climate data records. *Remote Sensing*, 12(20):3439.

Vereecken, H., Huisman, J., Pachepsky, Y., Montzka, C., Van Der Kruk, J., Bogaen, H., Weihermüller, L., Herbst, M., Martinez, G., and Vanderborght, J. (2014). On the spatio-temporal dynamics of soil moisture at the field scale. *Journal of Hydrology*, 516:76–96.

Villholth, K. G. (2013). Groundwater irrigation for smallholders in sub-saharan africa—a synthesis of current knowledge to guide sustainable outcomes. *Water International*, 38(4):369–391.

Vinnikov, K. Y., Robock, A., Qiu, S., Entin, J. K., Owe, M., Choudhury, B. J., Hollinger, S. E., and Njoku, E. G. (1999). Satellite remote sensing of soil moisture in illinois, united states. *Journal of Geophysical Research: Atmospheres*, 104(D4):4145–4168.

Vishwakarma, B. D., Bates, P., Sneeuw, N., Westaway, R. M., and Bamber, J. L. (2021). Re-assessing global water storage trends from grace time series. *Environmental Research Letters*, 16(3):034005.

Wagner, W., Hahn, S., Kidd, R., Melzer, T., Bartalis, Z., Hasenauer, S., Figa, J., De Rosnay, P., Jann, A., Schneider, S., et al. (2013). The ascats soil moisture product: A review of its. *Meteorologische Zeitschrift*, 22(1):1–29.

Wahr, J., Molenaar, M., and Bryan, F. (1998). Time variability of the earth's gravity field: Hydrological and oceanic effects and their possible detection using grace. *Journal of Geophysical Research: Solid Earth*, 103(B12):30205–30229.

- Wang, J. and Forman, B. (2020). Improved terrestrial snow mass via multi-sensor assimilation of synthetic grace terrestrial water storage retrievals and synthetic amsr-e brightness temperature spectral differences. Technical report, Copernicus Meetings.
- Wang, J., Forman, B. A., Girotto, M., and Reichle, R. H. (2021). Estimating terrestrial snow mass via multi-sensor assimilation of synthetic amsr-e brightness temperature spectral differences and synthetic grace terrestrial water storage retrievals. *Water Resources Research*, 57(9):e2021WR029880.
- Wang, L., Chen, C., Du, J., and Wang, T. (2017). Detecting seasonal and long-term vertical displacement in the north china plain using grace and gps. *Hydrology and Earth System Sciences*, 21(6):2905–2922.
- Wang, R., Huston, S., Li, Y., Ma, H., Peng, Y., and Ding, L. (2018). Temporal stability of groundwater depth in the contemporary yellow river delta, eastern china. *Sustainability*, 10(7):2224.
- Wouters, B. and Schrama, E. J. (2007). Improved accuracy of grace gravity solutions through empirical orthogonal function filtering of spherical harmonics. *Geophysical Research Letters*, 34(23).
- Wu, W.-Y., Yang, Z.-L., Zhao, L., and Lin, P. (2022). The impact of multi-sensor land data assimilation on river discharge estimation. *Remote Sensing of Environment*, 279:113138.
- Yang, Y., Long, D., Guan, H., Scanlon, B. R., Simmons, C. T., Jiang, L., and Xu, X. (2014). Grace satellite observed hydrological controls on interannual and seasonal variability in surface greenness over mainland australia. *Journal of Geophysical Research: Biogeosciences*, 119(12):2245–2260.
- Yeh, P. J.-F., Swenson, S. C., Famiglietti, J. S., and Rodell, M. (2006). Remote sensing of groundwater storage changes in illinois using the gravity recovery and climate experiment (grace). *Water Resources Research*, 42(12).
- Yin, G. and Park, J. (2021). The use of triple collocation approach to merge satellite-and model-based terrestrial water storage for flood potential analysis. *Journal of Hydrology*, 603:127197.
- Yoo, C. and Kim, S. (2004). Eof analysis of surface soil moisture field variability. *Advances in Water Resources*, 27(8):831–842.
- Zhao, M., Velicogna, I., and Kimball, J. S. (2017). Satellite observations of regional drought severity in the continental united states using grace-based terrestrial water storage changes. *Journal of Climate*, 30(16):6297–6308.

Received: 2023-03-22

Reviewed: 2023-04-13 (undisclosed name); 2023-04-19 (undisclosed name)

Accepted: 2023-06-16

Using machine learning techniques to reconstruct the signal observed by the GRACE mission based on AMSR-E microwave data

Abstract

This study delves into the synergy between remote sensing and satellite gravimetry, focusing on the utilization of Advanced Microwave Scanning Radiometer (AMSR-E) data for modeling delta Total Water Storage (Δ TWS) values derived from the GRACE mission. Various machine learning algorithms were employed to investigate the concordance between Gravity Recovery and Climate Experiment (GRACE) and AMSR-E observations. Despite the limited correlation in circumpolar permafrost areas, Δ TWS was successfully modeled with an accuracy of a Root Mean Square Error (RMSE) of 3.5 cm. The Amazon region exhibited a notable model error, attributed to significant Δ TWS amplitude; the overall model quality was affirmed by Normalized Root Mean Square Error (NRMSE) and Nash-Sutcliffe Efficiency (NSE) metrics. Importantly, the effectiveness of AMSR-E Soil Moisture (SM) data, encompassing C (frequency of 4–8 GHz) and X (frequency of 8–12 GHz) ranges (~0.04 m and ~0.03 m wavelength, respectively) in modeling Δ TWS, even in heavily forested equatorial regions, was demonstrated.

Keywords

GRACE • AMSR-E • total water storage anomalies • soil moisture • remote sensors

Viktor Szabó¹,
Katarzyna Osińska-Skotak²,
Tomasz Olszak³

¹Department of Geodesy and Geodetic Astronomy,
Faculty of Geodesy and Cartography, Warsaw University
of Technology, Warsaw, Poland
e-mail: viktor.szabo.dokt@pw.edu.pl

²Department of Photogrammetry, Remote Sensing and
Spatial Information Systems, Faculty of Geodesy and
Cartography, Warsaw University of Technology,
Warsaw, Poland
e-mail: katarzyna.osinska-skotak@pw.edu.pl

³Department of Geodesy and Geodetic Astronomy,
Faculty of Geodesy and Cartography, Warsaw University
of Technology, Warsaw, Poland
e-mail: tomasz.olszak@pw.edu.pl

Received: 20 January 2024

Accepted: 21 April 2024

Introduction

Water, a crucial Earth resource (De Villiers 2001), necessitates continuous monitoring in order to understand planetary processes and predict extreme weather events. Utilizing hydrological models, remote sensing, and gravimetric sensors has become integral to climate-related research. Satellite gravimetry is a unique technique for monitoring mass transport and Earth's processes on a global scale. One such satellite mission is GRACE (Tapley et al. 2004; Wahr et al. 1998). SM is a pivotal hydrological variable, constituting a fundamental component of Δ TWS (Robinson et al. 2008). Both active and passive microwave observations enable the analysis of SM at both global and regional scales (Babaeian et al. 2019). One of the key remote sensors providing SM data was the AMSR-E mission. AMSR-E is an advanced microwave scanning radiometer, serving as a component of the Earth observation system (Njoku et al. 2005). Given the constraints associated with the spatiotemporal resolution of GRACE data, it is essential to uphold statistical significance when examining the potential synergy of GRACE data with sensors that offer higher measurement frequencies and spatial resolutions (Ioannidis 2005). In the literature, there is a significant amount of research that involves processing, merging, and analyzing data from gravimetric sensors in conjunction with other data with varying spatiotemporal resolutions (Eicker et al. 2014). The year-long gap between GRACE and GRACE-FO missions raises concerns about our understanding of ongoing climate change. With the increasing computational capabilities of computers, machine learning methods have gained significance in solving signal reconstruction problems. After the completion of the GRACE-FO mission, there will be a continued need to map various phenomena and their changes using existing data, along with further research in hydrological modeling (Hamshaw et al. 2018).

Numerous studies have already demonstrated the utility of machine learning models in various contexts. Early attempts to use Empirical Orthogonal Functions (EOF) were described by Becker et al. (2011). Sun et al. (2020) presented time series reconstructions of Δ TWS for sixty selected river basins, employing a comprehensive comparison of deep neural networks (DNN) and seasonal autoregressive integrated moving average (SARIMAX) models. Sun et al. (2021) presented a Δ TWS reconstruction using NOAA and CLSM data for major North American river basins. Artificial neural networks (ANN) were utilized by Seyoum and Milewski (2017), while Irgang et al. (2020) demonstrated the efficiency of convolutional neural networks (CNN). Babaeian et al. (2019) conducted studies focusing on African river basins, and Sun (2013) used multilayer perceptron (MLP) and ANN architectures. Spatiotemporal analysis, using random forest, extreme gradient boosting (XGBoost), and logistic regression was employed by Jing et al. (2020) in the case of the Nile River basin, setting standards for highly accurate hydrological parameter reconstructions based on GLDAS-2 data. Seyoum et al. (2019) applied decision trees to enhance high-resolution groundwater level anomalies, improving GLDAS model data with field observations. Additionally, Sun et al. (2019) utilized CNN models with VGG16, Unet, and Segnet architectures for the Indian subcontinent, proving the effectiveness of encoder-decoder network structures in Δ TWS reconstruction.

The main goal of this publication is to show the possibility of using satellite microwave data (AMSR-E) to recreate the waveform observed by the gravimetric GRACE satellite mission on a global and local scale. To validate the experiment on a local scale, absolute gravimetric measurements were used. The underlying hypothesis posits that the ML methods applied to remote sensing AMSR-E data can effectively bridge the

gaps in the GRACE mission data, serving as the independent variable in various regression approaches. Previous research endeavors encompassed diverse models and techniques to reconstruct the temporal variations in ΔTWS , frequently relying on SM data sourced from alternative sensors, indicating the tremendous importance of this feature over other predictors. The present study seeks to augment the existing body of literature by comprehensively examining various regression methodologies to reconstruct the GRACE-derived signal.

Target data – GRACE

The processed data from the GRACE mission, representing ΔTWS , are available on the PODAAC website (Physical Oceanography Distributed Active Archive Center 2023) and are distributed by the Center for Space Research (CSR) in Texas. The spatial resolution of the GRACE data used in this study is approximately $300 \text{ km} \times 300 \text{ km}$. The data concerning changes in mass on the Earth's surface and subsurface are based on the RL06 standard (Dahle et al. 2013) at the level of L2 data processing. During the GRACE data processing, the C_{20} coefficient, representing the Earth's gravitational flattening (Swenson et al. 2008a), was replaced with observations using the Satellite Laser Ranging (SLR) technique (Cheng & Tapley 2004). The error associated with the N-S stripes, resulting from orbit inclination, was removed using a modified decorrelation filter (Chen et al. 2007; Swenson & Wahr 2006). Additionally, during the GRACE data processing, the static part of the gravitational field was corrected using the GGM05C model (Ries et al. 2016). While processing GRACE data, degree 1 coefficients (Geocenter) were estimated using the methods presented in the work of Swenson et al. (2008b). Correction due to the glacial isostatic adjustment (GIA) was considered, based on the ICE6G-D model, as presented in the study by Peltier et al. (2018).

Predictors data – AMSR-E

The AMSR-E dataset is available as daily measurement files on the NASA website (NASA's Goddard Earth Sciences Data and Information Services Center, 2023). The AMSR-E/Aqua surface SM descending dataset, version 2, is a Level 3 dataset in grid format, with a daily temporal resolution and a spatial resolution of approximately $25 \text{ km} \times 25 \text{ km}$. AMSR-E uses the X-band and C-band to measure the water cycle and SM content retrievals, corresponding to depths of 2.5–3.75 cm and 3.75–7.5 cm, respectively. Land surface SM measurements are derived from passive microwave remote sensing data using LPRM (Land Parameter Retrieval Model). LPRM leverages a radiative transfer model to obtain near-surface SM and optical depth of signal penetration. AMSAT-E on NASA's EOS Aqua satellite discontinued data provision in October 2011 due to issues with its antenna rotation (van der Vliet et al. 2020). This study exclusively utilized descending orbits, primarily due to their superior stability for soil temperature, vegetation cover, and nighttime air conditions (Liu et al. 2012).

True validation data – absolute gravimetric measurements

The JOZE gravimetric station is situated beneath the facilities of the Astronomical-Geodetic Observatory (AGO) in Józefosław, Poland, precisely 5.7 meters below the surface. It is anchored to a concrete pillar measuring 2×2 meters. Absolute measurements were conducted at approximately monthly intervals, from May 2005 to November 2016, employing the FG-5 gravimeter, serial number 230. This dataset represents the longest and most uniformly collected time series of absolute gravimetric values in Poland. The total uncertainty in determining the gravity amounted to $\pm 2 \text{ } \mu\text{Gal}$. The results of absolute measurements are meticulously adjusted to account for Earth tides (following the Wenzel model), oceanic tides (based on

the FES2004 model), atmospheric pressure fluctuations, and polar motion in accordance with IUGRS standards (Wziontek et al. 2021). In addition, gravitational values are further refined by incorporating the outcomes of ICAG and ECAG international comparison meetings to define common international gravity reference values and metrological factors stemming from variations in clock and laser frequencies.

Methods

Machine learning encompasses various problem types where these algorithms find application. Signal reconstruction is effectively addressed through regression modeling, using machine learning algorithms. The regression problem involves predicting a continuous response variable based on a given set of predictors. Regression models are techniques for creating a mathematical equation defining y as a function of the variables X . Linear regression is the simplest and most widely used technique for predicting a continuous variable and is defined by the formula:

$$Y = X\beta_1 + \beta_0 + \epsilon \quad (1)$$

Here, β_0 is the intercept, β_1 is the regression coefficient associated with the predictor variable (feature or attribute) X , and ϵ represents Gaussian noise.

The selection of regression algorithms for this study was guided by their established efficacy in handling diverse datasets and features, and their suitability for modeling the phenomenon under investigation. Drawing from prior research (Bonaccorso 2018; Maulud & Abdulazeez 2020), which evaluated various machine learning algorithms for regression tasks, we identified several popular methods for their robust performance across different data characteristics. Leveraging diverse methods ensured a comprehensive exploration of the regression landscape and facilitated robust modeling of the target phenomenon. The selected algorithms encompass a range of approaches, from ensemble methods such as Random Forest Regressor and Extra Trees Regressor, known for their ability to capture complex relationships in large datasets, to gradient boosting algorithms such as Extreme Gradient Boosting (XGBoost) and Gradient Boosting Regressor, which excel in handling high-dimensional data and achieving superior predictive accuracy. Additionally, traditional linear models, such as linear regression and ridge regression, were included, which, despite their simplicity, often serve as reliable baselines for comparison. Bayesian Ridge regression was chosen for its ability to balance model complexity and goodness of fit through Bayesian analysis. At the same time, the Huber Regressor was selected for its robustness to outliers, a common challenge in real-world datasets. Furthermore, more specialized techniques, such as Orthogonal Matching Pursuit and Lasso Regression, offer sparse solutions by selecting only the most relevant features, thus aiding in model interpretability. Elastic Net, a hybrid regularization method combining L1 (Lasso) and L2 (Ridge) penalties, was included to address potential collinearity among predictor variables, enhancing the stability of parameter estimates. To provide a comprehensive evaluation, ensemble methods, such as AdaBoost Regressor, known for their ability to combine multiple weak learners in order to improve predictive performance adaptively, were also considered, and Passive Aggressive Regressor, a variant of the passive aggressive algorithm, adapted specifically for regression tasks, offering flexibility in adjusting model parameters in response to observed errors.

Methods of fitting trigonometric functions were chosen as a reference point. A custom script, written in Python, was used for calculations using open-source libraries such as scikit-learn, PyCaret, and numpy.

The experiment focused on the intersection of GRACE and AMSR-E sensor datasets over the 2002–2012 period, which were strategically chosen to maximize dataset overlap. Input data for model training were meticulously organized into a tabular format, where each data point corresponds to a point in the matrix, and represents different measurement epochs. The columns contain variables derived from SM AMSR-E Band C and Band X determination, latitude, longitude, and monthly/semi-annual factors. This matrix corresponds to a vector, containing continuous Δ TWS variables, which are marked as the target variable. Subsequently, all these matrices have been amalgamated into a single table with dimensions equivalent to the number of epochs multiplied by the number of data points, and further multiplied by the number of variables.

Prior to the training phase, a distinct portion of randomly selected data should be set aside for the purpose of accuracy testing and model evaluation. It is crucial to ascertain the appropriate sample size for the test data to attain statistical significance, given the lack of substantial variance in the mean values between the two groups (Ioannidis 2005). To obtain statistical significance of the model results, the minimum number of samples included in the test set was determined. Data from 2002–2008 were included in the training set, and data from 2008–2012 were included in the test set.

Comparative analyses necessitate quality metrics to evaluate model performance, which is dependent on the analysis type and data characteristics. This work utilizes metrics such as NSE (Nash 1970), the coefficient of determination (R^2) (Nagelkerke 1991), Root Mean Square Error (RMSE) (Chai & Draxler 2014), and Normalized Root Mean Square Error. NSE is a normalized statistic that quantifies the relative size of the residual variance to the variance of the measured data. NSE is calculated using the following formula:

$$NSE = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_{sim})^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (2)$$

where: n represents the number of observations, y_i is the actual value of observation i , $\hat{y}_i$ is the predicted value for observation i by the model, and $\bar{y}$ is the mean value of all observations. The coefficient RMSE is calculated using the following formula:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (3)$$

RMSE is a measure of the deviation between actual values y_i and model-predicted values $\hat{y}_i$. A lower RMSE value indicates a better fit of the model to the actual data. The coefficient NRMSE is calculated using the following formula:

$$NRMSE = \frac{RMSE}{|max(y) - min(y)|} \quad (4)$$

where: $max(y)$ and $min(y)$ are the maximum and minimum values in the set of actual data y . In the context of GRACE data analysis, we are dealing with the amplitude of a phenomenon in a specific area. NRMSE is a measure of the deviation between model-predicted values and actual data, normalized to the data value range.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (5)$$

In this formula: y_i is the actual value of observation i , $\hat{y}_i$ is the predicted value for observation i by the model, and $\bar{y}$ is the mean value of all observations. R^2 is a measure that assesses how well a regression model fits the data. The value of R^2 ranges from 0 to 1, where 1 indicates a perfect fit of the model to the data. The Nash-Sutcliffe model efficiency coefficient closely resembles the coefficient of determination, differing from R^2 in its application. R^2 serves as an indicator of the quality of fit for a statistical model. In contrast, NSE is utilized to quantify a model's capability to forecast the outcome variable.

Global results and discussion

The achieved results on the test data sample are presented in table 1. The best results were obtained from methods related to Random Forests, such as Random Forest Regressor, Extra Trees Regressor, and Extreme Gradient Boosting, achieving satisfactory R^2 values greater than 0.7.

The results align with established benchmarks. For example, Sun et al. (2020) achieved impressive metrics in their temporal approach, including RMSE of 4.5–4.7 cm and NSE of 0.7. RMSE results of 4.5–4.7 cm can be observed (Szabó 2023) and RMSE of 4.2–4.5 cm, depending on the temporal and spatiotemporal scales considered. In a spatial and temporal context, Sun et al. (2021) achieved strong Nash-Sutcliffe efficiency (ca. 0.85), and low mean Normalized Root Mean Square Error (ca. 0.09) over the US. In a Nile River basin case study, using the spatiotemporal method (Jing et al. 2020), results revealed RMSE of 1.4–3.47 cm and NSE of 0.54–0.94. Using CNN networks, at a grid-based scale, showed promising results, with NSE of 0.87 in the Indian study area. However, RMSE values of 4.5–5.0 cm provide limited insight into solution quality. For a more comprehensive assessment, and considering the error-scale ratio, NRMSE serves as a superior metric, with the spatiotemporal approach benefiting from the increased variance in individual observations.

Local results and discussion

Measurements conducted with an absolute gravimeter are influenced by systematic geodynamic effects, which are accounted for during data processing and the local hydrological environment. Alongside gravity measurements at AGO JOZE, groundwater levels were monitored through a piezometer. By assessing the influence of nearby subsurface water bodies, a comparison between ground-based and satellite data was feasible. The methodology outlined in the work of Kuczynska-Siehien et al. (2019) and Szabó and Marjańska (2020) was employed to process absolute gravity data. The Δ TWS prediction results and the given gravity disturbance are presented in figure 3. The signal is accurately replicated with a high degree of precision, capturing the periodic changes effectively. However, in the presence of anomalies such as floods, the disparities between the model and observed values intensify.

In a study by Szabó and Osińska-Skotak (2023), the investigation reveals that the size of the river basin does not exhibit a direct correlation with the disparities in signals obtained from GRACE and AMSR-E. European rivers such as the Danube and Vistula exhibit concurrent shifts in hydrological signals when observed using both gravimetric and microwave remote sensors. Observations from the X- and C-bands introduce a more pronounced signal variance, compared with GRACE observations. Consequently, the identified anomalies are marked by heightened noise levels within these frequency ranges.

Table 1: The achieved results on the test data sample

Model	RMSE [m]	R ²	Δ RMSE [%]	Δ R ² [%]	1-R ²	Δ 1-R ² [%]
Random Forest Regressor	0.035	0.761	51.3	380700.0	0.239	76.1
Extra Trees Regressor	0.035	0.757	50.9	378700.0	0.243	75.7
Extreme Gradient Boosting	0.037	0.739	48.9	369350.0	0.262	73.9
K Neighbors Regressor	0.038	0.725	47.7	362450.0	0.275	72.5
Light Gradient Boosting Machine	0.038	0.715	46.7	357750.0	0.285	71.5
Decision Tree Regressor	0.048	0.546	32.8	273000.0	0.454	54.6
Gradient Boosting Regressor	0.052	0.469	27.3	234600.0	0.531	46.9
Linear Regression	0.069	0.074	3.9	36950.0	0.926	7.4
Least Angle Regression	0.069	0.074	3.9	36950.0	0.926	7.4
Bayesian Ridge	0.069	0.074	3.9	36900.0	0.926	7.4
Ridge Regression	0.069	0.068	3.7	34150.0	0.932	6.8
Huber Regressor	0.070	0.062	3.2	31000.0	0.938	6.2
Orthogonal Matching Pursuit	0.072	0.000	0.2	50.0	1.000	0.0
Lasso Regression	0.072	-0.001	0.2	-150.0	1.001	0.0
Elastic Net	0.072	-0.001	0.2	-150.0	1.001	0.0
Lasso Least Angle Regression	0.072	-0.001	0.2	-150.0	1.001	0.0
Dummy Regressor	0.072	-0.001	0.2	-150.0	1.001	0.0
AdaBoost Regressor	0.073	-0.021	-0.9	-10450.0	1.021	-2.1
Passive Aggressive Regressor	0.086	-0.485	-20.0	-242550.0	1.485	-48.5
sin+cos annual function (baseline)	0.072	0.000	-	-	1.000	
sin+cos semiannual function	0.095	0.000	-32.7	0.0	1.000	0.0

Source: own elaboration




Figure 1. Random Forest Regressor model: (a) residuals; (b) prediction identity

Source: own elaboration

Similar to the cited study, the flood wave prediction, based on SM data from AMSR-E, was unsuccessful in this case. Metrics for predictions for this location show the following values: NSE = -0.19, RMSE = 0.04 [m], NRMSE = 0.23, R² = 0.27, and confirm that the determination of anomalies in this area, visible in local absolute measurements in 2010–2011, is unsuccessful.

However, clear correlations between absolute measurements and SM from AMSR-E are visible in given periods. The negative anomaly from December 2009 was visible in both time series. This demonstrates the sensitivity of the gravimetric signal to environmental changes in the top aquifers.




Figure 2. Random Forest Regressor model spatial distribution of metrics: (a) NSE; (b) RMSE; (c) NRMSE; (d) R^2
Source: own elaboration




Figure 3. (a) Predicted ΔTWS and true ΔTWS with SM predictors from AMSR-E; (b) Predicted ΔTWS and true ΔTWS with dg validation data
Source: own elaboration

Conclusions

This study employs AMSR-E remote sensing data to model Δ TWS values, based on observations from the GRACE mission, testing various machine learning algorithms. Naturally forested and agricultural open regions exhibit a strong concordance between GRACE and AMSR-E data, emphasizing the importance of well-oxygenated soil root zones (Szabó & Osińska-Skotak 2023). The presence of permafrost restricts the applicability of X- and C-band microwave observations. Despite limited correlation in permafrost areas, Δ TWS values are accurately modeled with an RMSE of 3.5 cm. The Amazon region displays a notable model error, associated with the substantial amplitude of Δ TWS. However, metrics such as NRMSE and NSE affirm the overall quality of the model. AMSR-E SM data effectively models Δ TWS, even in equatorial forests. Challenges arise in the Mississippi River basin, the Great Plains, and Patagonia, where agricultural intensification leads to significant residuals from true observations. Factors influencing this may include connections with the irrigation of agricultural areas, faster water permeability to deeper aquifers in open areas, different vegetation periods, or other phenological factors. In the context of the approximately one-year gap between GRACE and GRACE-FO data, using existing data to model and complement the time series of gravimetric observations is extremely important. Data from remote sensing missions can be successfully used to achieve this goal.

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 article.

Abbreviations

AMSR-E – Advanced Microwave Scanning Radiometer
C20 – coefficient representing the Earth's gravitational flattening

CSR – Center for Space Research
ECAG – European Comparison Absolute Gravimetry
FES2004 – (Finite Element Solution) ocean tidal model, developed in 2004
FG-5 – A ballistic absolute gravimeter
GGM05C – GRACE Gravity Model 05 – the global Earth gravity model
GIA – glacial isostatic adjustment
GRACE – Gravity Recovery and Climate Experiment
ICAG – International Comparison Absolute Gravimetry meeting
ICE6G-D model – Glacial Isostatic Adjustment Model
JOZE – gravimetric station acronym of the Astronomical-Geodetic Observatory in Józefosław, Poland
L2 – Level 2 data processing
LPRM – Land Parameter Retrieval Model
NASA – National Aeronautics and Space Administration
NRMSE – Normalized Root Mean Square Error
NSE – Nash-Sutcliffe Efficiency
PODAAC – Physical Oceanography Distributed Active Archive Center
R2 – coefficient of determination
RL06 – Reprocessing Level 06
RMSE – Root Mean Square Error
SLR – Satellite Laser Ranging
SM – Soil Moisture
 μ Gal – microGal (10^{-8} ms $^{-2}$)
 Δ TWS – delta Total Water Storage

ORCID

Viktor Szabó  <https://orcid.org/0000-0002-8980-2442>
Katarzyna Osińska-Skotak  <https://orcid.org/0000-0003-2602-4281>
Tomasz Olszak  <https://orcid.org/0000-0001-6474-5448>

References

- Ahmed, M, Sultan, M, Elbayoumi, T & Tissot, P 2019, 'Forecasting grace data over the African watersheds using artificial neural networks', *Remote Sensing*, vol. 11, no. 15, article number 1769.
- Babaeian, E, Sadeghi, M, Jones, SB, Montzka, C, Vereecken, H & Tuller, M 2019, 'Ground, proximal, and satellite remote sensing of soil moisture', *Reviews of Geophysics*, vol. 57, no. 2, pp. 530–616.
- Becker, M, Meyssignac, B, Xavier, L, Cazenave, A, Alkama, R & Decharme, B 2011, 'Past terrestrial water storage (1980–2008) in the amazon basin reconstructed from GRACE and in situ river Gauging data', *Hydrology and Earth System Sciences*, vol. 15, no. 2, pp. 533–546.
- Bonaccorso, G 2018, *Machine Learning Algorithms: Popular algorithms for data science and machine learning*. Packt Publishing Ltd, Birmingham, UK.
- Chai, T & Draxler, RR 2014, 'Root mean square error (RMSE) or mean absolute error (MAE)? – arguments against avoiding RMSE in the literature', *Geoscientific model development*, vol. 7, no. 3, pp. 1247–1250.
- Chen, JL, Wilson, CR, Tapley, BD & Grand, S 2007, 'Grace detects coseismic and postseismic deformation from the Sumatra-Andaman earthquake', *Geophysical Research Letters*, vol. 34, no. 13, pp. 1–5.
- Cheng, M & Tapley, BD 2004, 'Variations in the Earth's oblateness during the past 28 years', *Journal of Geophysical Research: Solid Earth*, vol. 109(B9), pp. 1–9.
- Dahle, C, Flechtner, F, Gruber, C, König, D, König, R, Michalak, G & Neumayer, K-H 2013, *GFZ GRACE Level-2 processing standards document for level-2 product release 0005: revised edition*, Scientific Technical Report STR12/02 – Data. Available from: <http://icgem.gfz-potsdam.de/L2-GFZ_ProcStds_0005_v1.1-1.pdf>. [10 January 2024].
- De Villiers, M 2001, *Water: The fate of our most precious resource*. Houghton Mifflin Harcourt, New York, USA.
- Eicker, A, Schumacher, M, Kusche, J, Döll, P & Schmied, HM 2014, 'Calibration/data assimilation approach for integrating GRACE data into the watgap global hydrology model (WGHM) using an ensemble Kalman filter: First results', *Surveys in Geophysics*, vol. 35, no. 6, pp. 1285–1309.
- Hamshaw, SD, Dewoolkar, MM, Schroth, AW, Wemple, BC & Rizzo, DM 2018, 'A new machine-learning approach for classifying hysteresis in suspended-sediment discharge relationships using high-frequency monitoring data', *Water Resources Research*, vol. 54, no. 6, pp. 4040–4058.
- Ioannidis, JP 2005, 'Why most published research findings are false?', *PLOS Medicine*, vol. 2, no. 8(e124).
- Irrgang, C, Saynisch-Wagner, J, Dill, R, Boergens, E & Thomas, M 2020, 'Self-validating deep learning for recovering terrestrial water storage from gravity and altimetry measurements', *Geophysical Research Letters*, vol. 47, no. 17, article number e2020GL089258.
- Jing, W, Di, L, Zhao, X, Yao, L, Xia, X, Liu, Y, Yang, J, Li, Y & Zhou, C 2020, 'A data-driven approach to generate past

- GRACE-like terrestrial water storage solution by calibrating the land surface model simulations', *Advances in Water Resources*, vol. 143, article number 103683.
- Kuczynska-Siehiien, J, Piretzidis, D, Sideris, MG, Olszak, T & Szabó, V 2019, 'Monitoring of extreme land hydrology events in central Poland using GRACE, land surface models and absolute gravity data', *Journal of Applied Geodesy*, vol. 13, no. 3, pp. 229–243.
- Liu, Y, Dorigo, WA, Parinussa, R, de Jeu, RA, Wagner, W, McCabe, MF, Evans, J & Van Dijk, A 2012, 'Trend-preserving blending of passive and active microwave soil moisture retrievals', *Remote Sensing of Environment*, vol. 123, pp. 280–297.
- Maulud, D & Abdulazeez, AM 2020, 'A review on linear regression comprehensive in machine learning', *Journal of Applied Science and Technology Trends*, vol. 1, no. 4, pp. 140–147.
- Nagelkerke, NJD 1991, 'A note on a general definition of the coefficient of determination', *Biometrika*, vol. 78, no. 3, pp. 691–692.
- NASA's Goddard Earth Sciences Data and Information Services Center, 2023. Available from: <<https://disc.gsfc.nasa.gov/>>. [10 December 2023].
- Nash, J 1970, 'River flow forecasting through conceptual models. I: A discussion of principles', *Journal of Hydrology*, vol. 10, no. 3, pp. 398–409.
- Njoku, EG, Ashcroft, P, Chan, TK & Li, L 2005, 'Global survey and statistics of radio-frequency interference in AMSR-E land observations', *IEEE Transactions on Geoscience and Remote Sensing*, vol. 43, no. 5, pp. 938–947.
- Peltier, W, Argus, DF & Drummond, R 2018, 'Comment on "an assessment of the ICE-6G_C (VM5a) glacial isostatic adjustment model" by Purcell et al.', *Journal of Geophysical Research: Solid Earth*, vol. 123, no. 2, pp. 2019–2028.
- Physical Oceanography Distributed Active Archive Center, 2023. Available from: <<https://podaac-tools.jpl.nasa.gov/>>. [10 December 2023].
- Ries, J, Bettadpur, S, Eanes, R, Kang, Z, Ko, U, McCullough, C, Nagel, P, Pie, N, Poole, S, Richter, T, Save, H & Tapley, B, 2016, *The combined gravity model GGM05C*, GFZ Data Services.
- Robinson, DA, Campbell, CS, Hopmans, JW, Hornbuckle, BK, Jones, SB, Knight, R, Ogden, F, Selker, J & Wendroth, O 2008, 'Soil moisture measurement for ecological and hydrological watershed-scale observatories: A review', *Vadose Zone Journal*, vol. 7, no. 1, pp. 358–389.
- Seyoum, WM, Kwon, D & Milewski, AM 2019, 'Downscaling GRACE TWSA data into high-resolution groundwater level anomaly using machine learning-based models in a glacial aquifer system', *Remote Sensing*, vol. 11, no. 7, article number 824.
- Seyoum, WM & Milewski, AM 2017, 'Improved methods for estimating local terrestrial water dynamics from GRACE in the northern high plains', *Advances in water resources*, vol. 110, pp. 279–290.
- Sun, AY 2013, 'Predicting groundwater level changes using GRACE data', *Water resources research*, vol. 49, no. 9, pp. 5900–5912.
- Sun, AY, Scanlon, BR, Save, H & Rateb, A 2021, 'Reconstruction of GRACE total water storage through automated machine learning', *Water Resources Research*, vol. 57, no. 2, article number e2020WR028666.
- Sun, AY, Scanlon, BR, Zhang, Z, Walling, D, Bhanja, SN, Mukherjee, A & Zhong, Z 2019, 'Combining physically based modeling and deep learning for fusing GRACE satellite data: can we learn from mismatch?', *Water Resources Research*, vol. 55, no. 2, pp. 1179–1195.
- Sun, Z, Long, D, Yang, W, Li, X & Pan, Y 2020, 'Reconstruction of GRACE data on changes in total water storage over the global land surface and 60 basins', *Water Resources Research*, vol. 56(4), article number e2019WR026250.
- Swenson, S, Chambers, D & Wahr, J 2008a, 'Estimating geocenter variations from a combination of GRACE and ocean model output', *Journal of Geophysical Research: Solid Earth*, vol. 113, no. B8, pp. 1–12.
- Swenson, S, Famiglietti, J, Basara, J & Wahr, J. 2008b, 'Estimating profile soil moisture and groundwater variations using GRACE and Oklahoma Mesonet soil moisture data', *Water Resources Research*, vol. 44, no. 1, pp. 1–12.
- Swenson, S & Wahr, J 2006, 'Post-processing removal of correlated errors in GRACE data', *Geophysical research letters*, vol. 33, no. 8, pp. 1–4.
- Szabó, V & Marjańska, D 2020, 'Accuracy analysis of gravity field changes from GRACE RL06 and RL05 data compared to in situ gravimetric measurements in the context of choosing optimal filtering type', *Artificial Satellites*, vol. 55, no. 3, pp. 100–117.
- Szabó, V & Osińska-Skotak, K 2023, 'Similarities and differences in the Earth's water variations signal provided by GRACE and AMSR-E observations using maximum covariance analysis at various land cover data backgrounds' *Artificial Satellites*, vol. 58, no. 2, pp. 63–87.
- Szabó, V 2023, 'Comparison features importance for temporal and spatial-temporal approaches in GRACE and GRACE-FO signal reconstruction based on GLDAS data', *International Journal of Hydrology Science and Technology*, vol. 16, no. 4, pp. 370–389.
- Tapley, BD, Bettadpur, S, Watkins, M & Reigber, C 2004, 'The gravity recovery and climate experiment: Mission overview and early results', *Geophysical research letters*, vol. 31, no. 9.
- van der Vliet, M, van der Schalie, R, Rodriguez-Fernandez, N, Colliander, A, de Jeu, R, Preimesberger, W, Scanlon, T & Dorigo, W 2020, 'Reconciling flagging strategies for multi-sensor satellite soil moisture climate data records', *Remote Sensing*, vol. 12, no. 20, article number 3439.
- Wahr, J, Molenaar, M & Bryan, F 1998, 'Time variability of the Earth's gravity field: Hydrological and oceanic effects and their possible detection using GRACE', *Journal of Geophysical Research: Solid Earth*, vol. 103, no. B12, pp. 30205–30229.
- Wziontek, H, Bonvalot, S, Falk, R, Gabalda, G, Mäkinen, J, Pálínkáš, V, Rülke, A & Vitushkin, L 2021, 'Status of the International Gravity Reference System and Frame', *Journal of Geodesy* vol. 95 no. 7.