

# TELEDETEKCJA ŚRODOWISKA

ISSN 0071-8076

dawniej **FOTOINTERPRETACJA** w GEOGRAFII

## 48

WARSZAWA 2012

[http://telegeo.wgsr.uw.edu.pl/Teledetekcja\\_Srodowiska/czasopismo\\_pl.html](http://telegeo.wgsr.uw.edu.pl/Teledetekcja_Srodowiska/czasopismo_pl.html)

### Spis treści – Contents

<b>Wstęp</b> .....	8
<i>Introduction</i>	
<b>Cel pracy</b> .....	8
<i>Aim of the study</i>	
<b>Badania łąk na terenie Polski</b> .....	8
<i>Grassland research in Poland</i>	
<b>Zastosowanie teledetekcji w badaniach łąkarskich</b> .....	11
<i>Application of remote sensing in grassland studies</i>	
<b>Teledetekcyjne monitorowanie stanu roślinności</b> .....	12
<i>Vegetation monitoring using remote sensing</i>	
<b>Hiperspektralne badania roślinności na świecie</b> .....	12
<i>Vegetation researches using hyperspectral data</i>	
<b>Wykorzystanie modeli transferu promieniowania w badaniach roślinności</b> .....	14
<i>Application of Radiative Transfer Models in vegetation analysis</i>	
<b>Modelowanie roślinności na poziomie pojedynczych liści</b> .....	16
<i>Vegetation modelling on leaf level</i>	
<b>Modelowanie roślinności na poziomie pokrywy roślinności</b> .....	16
<i>Vegetation modelling on canopy level</i>	
<b>Charakterystyka środowiska badanych terenów</b> .....	19
<i>Environmental characteristics of studied areas</i>	
<b>Metodyka badań</b> .....	23
<i>Methods</i>	
<b>Modelowanie odbicia promieniowania od pojedynczych liści</b> .....	23
<i>Reflectance modelling on leaf level</i>	
<b>Modelowanie odbicia promieniowania od roślinności na poziomie pokrywy roślinnej</b> .....	24
<i>Reflectance modelling on canopy level</i>	
<b>Weryfikacja i opracowanie wyników badań</b> .....	28
<i>Verification and elaborated of the research results</i>	
<b>Skuteczność modelowania charakterystyk spektralnych</b> .....	28
<i>Efficiency modelling of the spectral reflectance</i>	

<b>Symulacja charakterystyk spektralnych na poziomie pojedynczych liści z użyciem modelu PROSPECT</b> .....	29
<i>Simulation of the spectral reflectances on the single leaves level with the PROSPECT model</i>	
<b>Symulacja charakterystyk spektralnych na poziomie pokrywy roślinnej z użyciem modelu PROSAIL</b> .....	36
<i>Simulation of the spectral reflectances on the canopy level with the PROSAIL model</i>	
<b>Podsumowanie wyników</b> .....	43
<i>Summary of the results</i>	
<b>Dyskusja wyników</b> .....	44
<i>Discussion and Conclusion</i>	
<b>Literatura</b> .....	48
<i>References</i>	

## Ocena skuteczności modeli transferu promieniowania w badaniach stanu roślinności łąk

*Evaluation of radiative transfer models to simulate meadows reflectance*

Anna JAROCIŃSKA

**Słowa kluczowe:** łąki, krzywe odbicia spektralnego, Radiative Transfer Model, PROSPECT, SAIL

**Key words:** meadows, spectral reflectance, Radiative Transfer Model, PROSPECT, SAIL

**Otrzymano:** 30 sierpnia 2012; **Zaakceptowano:** 31 grudnia 2012

**Received:** 30 August 2012; **Accepted:** 31 December 2012

Vegetation analysis is an important problem in regional and global scale. Because of pollution of environment and changes in the ecosystems plant monitoring is very important. Remote sensing data can be easily used to plant monitoring. That kind of method is much faster and more reliable than traditional approaches. Spectrometry analyzes the interactions between radiation and object and it uses measurement of radiation intensity as a function of wavelength. Each object emits and absorbs different quantity of radiation, so it is possible to recognise the object and check its characteristics analysing the spectrum.

The subject of the researches is Polish meadows. The human usage of the meadows determines its proper functioning. Grasslands, which consist of meadows and pastures, cover 10% of Poland. Meadows are most extensively use. In Poland the crops from meadows (hay and green forage) are very low. The meadows in Poland are floristically and morphologically very diverse. Many factors influence on this ecosystem and that is why the monitoring is very important.

The aim of the researches is to study the possibility of use of the Radiative Transfer Models in modelling the state of the heterogeneous vegetation cover of seminatural meadows in Poland.

Two approaches are used to canopy analysis: statistical and modelling. In the statistic approach, biophysical parameters calculated from the image are correlated with reflectance or transmittance from field measurements. In second approach physically based model is used to represent the photon transport inside leaves and canopy. The Radiative Transfer Models are based on the laws of optics. Developing the model results in better understanding of the interaction of light in canopy and leaves. The Radiative Transfer Models are often applied to vegetation modelling. The Radiative Transfer Models are

physically based models which describe the interactions of radiation in atmosphere and vegetation. Adjusted models can be used to fast and precise analysis of biophysical parameters of the canopy.

The canopy can be described as homogeneous layer consisting of leaves and spaces. The Radiative Transfer Models are algorithms which vary by input and output parameters, the level of the analysis, kinds of plants and other modifications. Models are used on two levels: single leaf and whole canopy. The first model, which is used in this research, is PROSPECT, which describes the multidirectional reflectance and diffusion on a leaf level. It is often employed with other models that describe whole canopy. Leaf has the same properties on both sides, the reflection from the leaves is Lambertian. The input parameters in the model are: chlorophyll and carotenoid content, Equivalent Water Thickness and dry matter content and also leaf structure parameter that describe the leaf structure and complexity.

Second model, which is used in the study, is the canopy reflectance model SAIL (Scattering by Arbitrarily Inclined Leaves). It simulates the top of the canopy bidirectional reflectance and it describes the canopy structure in a fairly simple way. In this analysis the 4-SAIL model will be used. This version has few input parameters that describe plants and soil: spectrometric data – reflectance and transmittance from leaves (the output parameters form PROSPECT model), biophysical canopy parameters (Leaf Area Index, brown pigment content, mean leaf inclination angle), soil brightness parameter, reflectance geometry (solar zenith angle, observer zenith angle, relative azimuth angle), ratio of diffuse to total incident radiation and two hot spot size parameters. The SAIL model is often combined with the model on leaf level – the PROSAIL model. The PROSPECT and SAIL are very rarely used to meadows,

because this kind of ecosystem is normally rather heterogeneous and modelling is quite difficult.

In this study two Radiative Transfer Models (PROSPECT-5 and 4SAIL) were used on single leaves and a whole canopy level. In order to acquire the input data to both, models model and reference spectrums the field measurements were done. The input parameters were recalculated using fields measurements and put into the models: PROSPECT and PROSAIL. Only one leaf structure parameter was fitted for each polygon individually.

The spectral reflectance obtained from the model was compared with field data. Based on the calculated Root Mean Square Error the simulation was verified. The RMSE values were calculated for whole range from 400 to 2500 nm and for specific ranges. The correctness of simulated spectra were analysed dependent on the type of meadows (cultivated meadows with reduced amount of biomass, cultivated meadows with high amount of biomass and not cultivated meadows) and

the value of three different biophysical parameters (Leaf Area Index, fresh biomass content and water content).

Better results were obtained using PROSPECT model than PROSAIL. In the visible light more accurate values were calculated using PROSAIL and in the infrared using PROSPECT. Generally bigger errors were noticed in the infrared, especially middle infrared range. The effectiveness of the reflectance simulation was not influenced by different kind of meadows. Apart from that, better results were obtained on meadows with higher biomass value, bigger Leaf Area Index and lower water content.

Generally, the PROSPECT and PROSAIL radiative transfer models can be used to simulate the spectral reflectance of vegetation on heterogeneous meadows. The models can be used to estimate the biophysical parameters, but it is necessary to correct the values of input variables (especially water content). Meadows are very complex environment and some of the parameters should be adjusted.

## Wstęp

### Introduction

### Cel pracy

#### Aim of the study

Badanie stanu roślinności, w tym monitoring pokrywy roślinnej, jest istotnym problemem w skali globalnej, regionalnej i lokalnej. Monitorowanie zmian w szacie roślinnej pozwala na określenie zmian czasowych zachodzących w innych komponentach środowiska mających wpływ na rośliny, takich jak gleba czy stosunki wodne.

Zastosowanie teledetekcji w badaniach roślinności datuje się niemal od początku rozwoju tej dyscypliny. Metody te dają możliwość szybkiego zbierania synoptycznych danych o szacie roślinnej oraz uzyskanie na ich podstawie wielu nowych informacji. Podstawą tych badań jest rejestracja promieniowania elektromagnetycznego odbijanego od roślin.

W monitoringu roślinności z wykorzystaniem danych teledetekcyjnych stosowane są dwie metody: statystyczna i modelowanie (Jacquemoud, 1993; Kumar, Schmidt, Dury, Skidmore, 2006). W przypadku pierwszej z nich konieczne jest przeprowadzanie jednocześnie pomiarów terenowych podczas wykonywania zobrazowania. Aby pozyskać informacje o parametrach biofizycznych roślin na podstawie obrazu, konieczne jest skorelowanie zmierzonych w terenie zmiennych z danymi z pułapu lotniczego lub satelitarnego, nie ma bowiem możliwości bezpośredniego pozyskania tych informacji z charakterystyk spektralnych. Dlatego wprowadzono drugą metodę badawczą – modelowanie z wykorzystaniem modeli transferu promieniowania. W wyniku ich zastosowania możliwe jest obliczenie parametrów biofizycznych roślin na podstawie wartości odbicia spektralnego. Te informacje pozwalają na określenie stanu roślin, a także prognozowanie plonów.

Modele transferu promieniowania (*Radiative Transfer Models* – RTM) są stosowane do wielu siedlisk roślin-

nych. Jeśli symulacja danych hiperspektralnych jest skuteczna, modele po odwróceniu mogą być używane także do pozyskiwania informacji o parametrach biometrycznych i biofizycznych roślin z krzywych odbicia spektralnego. Jest to najbardziej skuteczna i wiarygodna metoda pozyskiwania danych. Tym samym przy zastosowaniu odpowiedniego modelu można obliczyć parametry określające stan roślinności, na przykład zawartość w roślinach chlorofilu, wody, a także szacować biomasa.

Modele transferu promieniowania są bardzo rzadko stosowane do symulowania charakterystyk spektralnych roślin łąkowych. Przeprowadzone badania pozwoliły określić, czy jest możliwa symulacja odbicia spektralnego, w jakim stopniu jest poprawna i czy możliwe jest dalsze wykorzystywanie modeli transferu promieniowania w badaniach roślin łąkowych.

Celem niniejszych badań jest ocena skuteczności modeli transferu promieniowania do określania stanu szaty roślinnej łąk występujących na terenie Polski. W badaniach przetestowano dwa modele transferu promieniowania, służące do symulowania odbicia promieniowania od pojedynczych liści i szaty roślinnej traktowanej jako jednolita pokrywa roślinna, z punktu widzenia poprawności symulowania krzywych odbicia spektralnego. Zbadano i oceniono istotność czynników wpływających na skuteczność symulowania odbicia spektralnego od zróżnicowanej pod względem składu gatunkowego roślinności łąkowej. Badania odbywały się na obszarach łąkowych, które ze względu na duże zróżnicowanie wewnętrzne są trudne do modelowania.

### Badania łąk na terenie Polski

#### Grassland research in Poland

Dane hiperspektralne są pozyskiwane z poziomu naziemnego oraz pułapów lotniczego i satelitarnego. Dane charakteryzują się wysoką rozdzielczością spektralną. Według A. F. H Goetza, G. Vane'a, J. E. Solomona

i B. N. Rocka (1985) powinny być rejestrowane w co najmniej 40 kanałach spektralnych o szerokości połowkowej od 10 do 20 nm. Obecnie rozdzielczość spektralna skanerów hiperspektralnych wynosi poniżej 10 nm i obejmuje zakres od widma widzialnego do środkowej podczerwieni (Zagajewski, 2010; [www.enmap.org](http://www.enmap.org), [www.ga.gov.au/earth-observation/satellites-and-sensors/eo-1-satellite.html](http://www.ga.gov.au/earth-observation/satellites-and-sensors/eo-1-satellite.html)).

W przypadku naziemnych badań spektrometrycznych rozdzielczość urządzeń przystosowanych do pomiarów hiperspektralnych jest wyższa niż w skanerach lotniczych bądź satelitarnych. Dlatego obrazy hiperspektralne mają mniejszą rozdzielczość spektralną niż dane z pomiarów naziemnych. Ograniczenie liczby kanałów jest wskazane ze względu na dużą objętość danych i trudności w przetwarzaniu tak dużych plików danych.

Szczegółowe dane o wielkości odbicia spektralnego pozwalają na dokładniejszą analizę roślinności niż w przypadku danych wielospektralnych. Przy użyciu danych hiperspektralnych można badać obszary antropogeniczne, szczególnie cenne są jednak w badaniach roślinności.

Wysoka rozdzielczość spektralna pozwala na badania właściwości biochemicznych roślin, a także ich struktury (Ustin, Roberts, Gamon, Asner, Green, 2004). Każdy obiekt absorbuje i odbija różną ilość promieniowania w zależności od długości fali elektromagnetycznej. Za pomocą analizy charakterystyk spektralnych, czyli wartości współczynnika odbicia zmierzonego w poszczególnych długościach fali elektromagnetycznej, możliwe jest bardzo precyzyjne badanie poszczególnych obiektów. Techniki hiperspektralne są stosowane w badaniach roślinności ze względu na możliwość określania budowy roślin, ich chemizmu, struktury komórkowej, biomasy, zawartości wody i kondycji roślin (Jensen, 1983).

Krzywe odbicia spektralnego roślin zielonych, w tym łąk, są do siebie zbliżone ze względu na główne substancje absorbujące i odbijające promieniowanie, które występują w roślinach zielonych. Światło przechodzące przez liście ulega odbiciu, absorpcji i transmisji albo kombinacji tych trzech procesów. Według L. Kumara, K. Schmidta, S. Dury'ego i A. Skidmore'a (2006) na optyczne właściwości liści roślin wpływają takie czynniki, jak: szorstkość powierzchni i współczynnik załamania światła przez wosk kutykularny, ilość i rozmieszczenie pigmentów w liściach, wewnętrzna struktura liści i zawartość wody. Każdy z tych czynników oddziałuje na różne zakresy widma elektromagnetycznego z właściwą sobie specyfiką. Na przykład, szorstkość powierzchni i wosk kutykularny wpływają na odbicie od górnej powierzchni liścia, pigmenty na absorpcję określonych zakresów promieniowania ultrafioletowego i widzialnego, struktura liścia na wewnętrzne rozproszenie światła, a zawartość wody wpływa na absorpcję promieniowania podczerwonego.

Na wielkość odbicia wpływ ma zarówno struktura, jak i skład chemiczny obiektu. Na ogół dane hiperspektralne obejmują zakres optyczny widma, czyli od około 0,4 do 2,5  $\mu\text{m}$ . W zakresie widzialnym od 0,4 do 0,7  $\mu\text{m}$

na wielkość odbicia wpływa zawartość pigmentów fotosyntetycznych, głównie chlorofilu, ksantofilu i karotenoidów (Ustin, Roberts, Gamon, Asner, Green, 2004). Chlorofil zawarty w liściach w znacznie większym stopniu niż światło zielone pochłania czerwone i niebieskie. W rejonie bliskiej podczerwieni, od 0,7 do 1,1  $\mu\text{m}$ , występuje duże odbicie, na które ma wpływ struktura wewnętrzna roślin – odbicie od miękiszu gąbczastego jest duże, mniejsze natomiast od miękiszu palisadowego. W zakresie od 0,87 do 1,24  $\mu\text{m}$  na absorpcję promieniowania wpływa woda i główne pierwiastki budujące liście. W średniej podczerwieni (1,3-2,5  $\mu\text{m}$ ) występuje silna absorpcja i niewielkie odbicie, co jest związane z zawartością wody w liściach. Jeśli liście są suche, to na wielkość odbicia wpływa zawartość podstawowych pierwiastków budujących roślinę.

Substancje biochemiczne, które wywierają dominujący wpływ na kształt i wartości krzywej odbicia spektralnego roślinności zielonej, to celuloza, hemiceluloza, lignina, skrobia, azot oraz komponenty: białka i pigmenty (Tretyn, 2007). Chlorofil absorbuje światło w zakresach 0,43, 0,66  $\mu\text{m}$  (chlorofil *a*) i 0,46, 0,64  $\mu\text{m}$  (chlorofil *b*). Białka, zawierające większość azotu, absorbują promieniowanie w następujących długościach fali: 1,5, 1,68, 1,74, 1,94, 2,05, 2,17, 2,29 i 2,47  $\mu\text{m}$ , a celuloza – 1,22, 1,48, 1,93, 2,1, 2,28, 2,34, 2,48  $\mu\text{m}$  i podczerwień termalną. Lignina pochłania promieniowanie w zakresie 1,45, 1,68, 1,93, 2,27, 2,33, 2,38, 2,5  $\mu\text{m}$  i w przedziale 2,05-2,14  $\mu\text{m}$ . Skrobia absorbuje promieniowanie o następujących długościach: 0,99, 1,22, 1,45, 1,56, 1,7, 1,77, 1,93, 2,1, 2,32 i 2,48  $\mu\text{m}$ .

Powyższe czynniki determinują kształt krzywej odbicia spektralnego, dlatego na podstawie wartości odbicia można wnioskować o zawartości poszczególnych substancji budujących rośliny. W związku z tym dane o dużej rozdzielczości spektralnej są przydatne do analiz roślinności, w tym także roślinności łąkowej.

Przedmiotem badań przedstawionych w tej pracy są łąki, czyli grunty zajęte pod uprawę traw lub innych upraw zielnych, naturalnych lub powstałych w wyniku działalności rolniczej. Łąka jest bezdrzewnym zbiorowiskiem roślinnym, na którym rośnie zwarte runo traw z domieszką innych roślin jednoliściennych, wieloletnich ziół i mszaków (Nawara, 2006). Istnienie łąk jest zależne od systematycznego wykaszania. Charakterystyczną cechą tych zbiorowisk jest to, że korzenie i rozłogi roślinności tworzą darń, dzięki której łąka może się odradzać po każdym skoszeniu i przerwie zimowej. Przy systematycznym koszeniu skład roślin utrzuca się.

Łąki wraz z pastwiskami składają się na użytki zielone. Trwałe użytki zielone porośnięte stale roślinnością, nie występujące na gruntach ornych jako płodozmian, zajmują w Polsce około 3 mln ha, co stanowi około 10% powierzchni kraju i ponad 20% powierzchni użytków rolnych (Kucharski, 2009). Nie wszystkie trwałe użytki zielone są powierzchnią produkcyjną, część bowiem jest zaniedbana bądź występuje na terenach niedostępnych lub na torfowiskach – terenach trudnych do eksploatacji jako użytki zielone. W związku z tym, szacuje się, że

około 70% użytków jest wykorzystywanych – koszonych lub wypasanych. W porównaniu z innymi państwami Europy, jak i rolę, jaką spełniają w kształtowaniu krajobrazu, ich udział w powierzchni kraju jest mały. Dlatego istotne jest ich utrzymanie, a także określanie ich stanu.

Łąki użytkowane są głównie kośnie, a pozyskiwaną z nich zieloną biomasę suszy się na siano lub zakisza. W Polsce przeważającą część plonów stanowi siano. Plony z łąk stanowią główne źródło pokarmu dla hodowlanych zwierząt roślinożernych. Biomasa z łąk można także wykorzystać do celów energetycznych. Terminy koszenia zależą od stopnia rozwoju roślin. W ciągu roku można uzyskać od jednego do trzech pokosów na łące, co zależy od rodzaju gleby, nawożenia mineralnego i nawadniania. Ponadto zbiorowiska trawiaste mogą służyć jako pastwiska.

Na terenie Polski gospodarka na trwałych użytkach zielonych jest prowadzona ekstensywnie, co jest widoczne w niskim poziomie plonów w postaci siana i zielonej masy. Potencjał łąk i pastwisk jest niedostatecznie wykorzystywany (Jankowska-Huflejt, Domański, 2008). Dlatego określenie wielkości uzyskiwanych plonów jest istotne.

Łąki pełnią ważne funkcje gospodarcze i ekologiczne. Oczyszczają powietrze, kształtują mikroklimat: łagodzą wahania temperatury i wilgotności powietrza (Nawara, 2006). Łąki w Polsce są zróżnicowane pod względem fitosocjologicznym i morfologicznym. Stanowią wartościowe siedliska rodzimych gatunków roślin i zwierząt, co ma związek z ich często naturalnym lub półnaturalnym charakterem. Flora łąk na terenie Polski liczy około 400 różnych roślin naczyniowych i kilkadziesiąt gatunków mszaków (Kucharski, 2009). Łąki stanowią także magazyn wód powierzchniowych i podziemnych. Chronią glebę przed erozją wodną i wietrzną. Hamują mineralizację gleb torfowych i torfowo-murszowych.

Ze względu na antropogeniczne pochodzenie łąki należą do środowisk zagrożonych, bo zarówno nadmierne użytkowanie, jak i zaniechanie użytkowania degradują środowisko, a doprowadzenie do poprzedniego stanu jest trudne (Kucharski, 2009). Przy braku użytkowania łąki zarastają roślinnością krzewiastą i drzewiastą. Także nadmierny wypas i koszenie powoduje szybsze wyczerpywanie się składników pokarmowych, zubożenie środowiska i sprawia, że rośliny nie mogą się odnowić. Zbyt niskie koszenie uniemożliwia szybkie odrastanie roślin, a także nie pozwala na osiedlanie się ptaków. Na różnorodność biologiczną łąk wpływa nie tylko koszenie, ale także nawożenie, które ma decydujący wpływ na ich skład gatunkowy. Na stan łąk ma wpływ stosowanie ciężkich maszyn, ponieważ zmieniają one stosunki wodno-powietrzne w glebie i mogą zniszczyć strukturę roślinności. Zwiększenie mechanizacji jest związane z komasacją gruntów i znacznie ułatwia zbiór siana, z drugiej zaś strony likwiduje zróżnicowanie środowiska łąkowego, a tym samym powoduje spadek bioróżnorodności tych terenów. Siedliska łąkowe ulegają degradacji przez przesuszenie i skażenie środowiska. Obniżenie poziomu wód gruntowych, szczególnie na glebach orga-

nicznych, powoduje mineralizację podłoża, co zwiększa eutrofizację siedlisk. Z przesuszonych siedlisk wycofują się rośliny wilgociolubne.

Podjęte badania, w których wykorzystano modele transferu promieniowania jako innowacyjną metodę badawczą, mają ułatwić rozwiązanie problemu monitorowania zbiorowisk trawiastych występujących na terenie Polski. Ze względu na wymienione wcześniej zagrożenia istotne jest badanie kondycji roślinności łąkowej.

Tematyka łąkarska jest dość często podejmowana przez polskich badaczy. Badania z tego zakresu można podzielić ze względu na tematykę i na stosowane techniki. Na ogół w badaniach wykonywanych w Polsce stosowano tradycyjne metody obserwacji – badania terenowe. Stosowane były również, choć stosunkowo rzadko, metody teledetekcyjne (Bochenek, 1990; Lewiński, Gruszczyńska, 1992; Ciołkosz, Dąbrowska-Zielińska, 1993; Kozłowska, Rogowski, Banaszek, 1994; Kozłowska, Dąbrowska-Zielińska, Ostrowski, Ciołkosz, Stankiewicz, Bochenek, 2000; Dąbrowska-Zielińska, Kowalik, Gruszczyńska, Hościło, 2003; Kozłowska, Kosiński, Kwiecień, Ziaja, 2004; Budzyńska, Dąbrowska-Zielińska, Turlej, Małek, Bartold, 2011).

W zakresie tematyki badawczej można wyróżnić opracowania dotyczące gleb na terenach łąkowych, badania siedliskowe w aspekcie składu florystycznego i jego zmian oraz stanu roślinności, badane bywa również użytkowanie łąk. Częste są opracowania poświęcone stosunkom wodnym, melioracjom i ich wpływowi na rozwój łąk. Najwięcej badań obejmuje nawożenie łąk, czynniki środowiskowe i ich wpływ na produktywność łąk. Ze względu na cel niniejszego opracowania najistotniejsze są publikacje dotyczące stanu roślinności i szacowania plonów.

Przykładem badań roślinności łąkowej były analizy zmian we florze pod wpływem czynników antropogenicznych (Kryszak, 2004; Kamiński, Chrzanowski, 2009) lub w zależności od rodzaju koszenia łąk (Kamiński, 2004; Radkowski, Kuboń, 2006), a także całego użytkowania terenów łąkarskich (Borawska-Jarmułowicz, 2004; Kiryluk, 2008). W wielu opracowaniach jest omawiane zagadnienie, w jaki sposób zaniechanie użytkowania łąk wpływa na skład florystyczny (Grzegorzczak, Grabowski, 2010). Inną kategorią badań są analizy kondycji roślinności na obszarze łąkowym. Przykładem badań jest analiza stresu wodnego różnych gatunków traw w kontrolowanych warunkach szklarniowych (Olszewska, Grzegorzczak, Olszewski, Bałuch-Małecka, 2010).

Szczególnie wiele uwagi w literaturze przedmiotu jest poświęcane zagadnieniu plonowania, a także czynnikom wpływającym na wielkość plonów, np. ze względu na nawożenie, skład florystyczny i sposób użytkowania (Kitczak, Czyż, 2003). Stwierdzono, że na łące kośnej zbiera się wyższy plon niż na łące przemiennie użytkowanej, a także znacznie większy jest udział roślin motylkowych. Badano także produktywność łąk w zależności od składu gatunkowego mieszanki i intensywności nawożenia (Bałuch-Małecka, Olszewska, 2008). Na podstawie poletka testowego określano, w jaki sposób

nawożenia wpływa na plony z łąk podsiewanych konkretną mieszanką roślin (Dradrach, Zdrojewski, 2008). Badano plony z łąk na terenach torfowych (Prokopowicz, Kowalczyk, 2007), a także plonowanie w zależności od nawożenia i nawadniania na glebach torfowo-murszowych (Prokopowicz, Jurczyk, 2008) i górskich (Kasperczyk, Szewczyk, 2006; Nadolna, Paszkiewicz-Jasińska, 2007; Kasperczyk, Kacprzyk, 2008). Część opracowań dotyczyła wpływu naturalnego nawożenia i gospodarowania w gospodarstwach ekologicznych na wielkość produkcji (Prokopowicz, Jankowska-Huflejt, 2007). Ponadto opisywano wpływ zaniechania nawożenia na zawartość poszczególnych pierwiastków w wodach i glebach łąk (Burzyńska, 2009).

### Zastosowanie teledetekcji w badaniach łąkarskich

#### *Application of remote sensing in grassland studies*

Do teledetekcyjnego badania właściwości pokrywy roślinnej są stosowane dwa podejścia: statystyczne i modelowanie (Jacquemoud, 1993; Kumar, Schmidt, Dury, Skidmore, 2006). W podejściu statystycznym koreluje się parametry roślinne określone w czasie pomiarów naziemnych z wartością odbicia. Tego typu badania są długotrwałe i kosztochłonne. Dotychczas w Polsce badania teledetekcyjne łąk, jak i innych zbiorowisk roślinności odbywały się przy zastosowaniu podejścia statystycznego. Najczęściej dotyczyły one badania kondycji roślinności, szacowania parametrów biofizycznych i klasyfikacji łąk.

Do badania stanu użytków zielonych wykorzystywano obrazy satelitarne AVHRR NOAA i lotnicze, które korelowano z danymi naziemnymi (Bochenek, 1990). Na podstawie wartości wskaźników teledetekcyjnych szacowano wskaźnik LAI, wielkość biomasy i wilgotność gleby. Badano zależności temperatury radiacyjnej pozyskanej z pułapu lotniczego i satelitarnego (Lewiński, Gruszczyńska, 1992) od parametrów biofizycznych roślin pobranych z poziomu naziemnego (LAI, biomasa świeża i wilgotność gleby). Temperatura radiacyjna była opracowana na podstawie obrazów AVHRR NOAA. Autorzy otrzymali dobre korelacje temperatury z biomasą świeżą i parametrem LAI z pomiarów terenowych. Badano także zastosowanie obrazów satelitarnych do określania produktywności łąk (Ciołkosz, Dąbrowska-Zielińska, 1993). W badaniach wykorzystano obrazy z NOAA, na podstawie których wyznaczono temperaturę radiacyjną, wskaźnik NDVI i określono LAI. Zajmowano się także modelem określającym plony z łąk z zastosowaniem obrazów satelitarnych (Kozłowska, Dąbrowska-Zielińska, Ostrowski, Ciołkosz, Stankiewicz, Bochenek, 2000). Ponadto badano warunki środowiskowe i kondycję łąk, wykorzystując temperaturę radiacyjną (Łabędzki, 2003).

Na podstawie badań terenowych i wskaźnika NDVI obliczonego z obrazów satelity Landsat TM analizowano możliwości badania wilgotności siedlisk łąkowych (Kozłowska, Rogowski, Banaszek, 1994). Badania wykazały, że nie da się bezpośrednio wyznaczyć stopnia wil-

gotności z obrazów satelitarnych, możliwe jest jednak wyznaczenie w przypadku niektórych rodzajów siedlisk zależności wskaźnika od wilgotności. Wskaźnik NDVI używany był także do badania użytkowania i uwilgotnienia łąk (Kozłowska, Kosiński, Kwiecień, Ziaja, 2004).

Zajmowano się odróżnianiem różnych siedlisk użytków zielonych. Na podstawie obrazów satelitarnych Landsat, obliczonych na ich podstawie wartości wskaźnika NDVI i jego rozkładu przestrzennego opracowano mapę przedstawiającą różne formy użytkowania ziemi, w tym rodzaje łąk (Kosiński, Kozłowska, 2003). Wykorzystując wskaźnik NDVI obliczony z obrazów z satelity Landsat opracowano algorytm półautomatycznej klasyfikacji obiektowej do klasyfikacji łąk (Kosiński, Hoffmann-Niedek, 2008).

Z użyciem danych teledetekcyjnych opracowane zostały metody monitorowania bagien Biebrzańskich (Dąbrowska-Zielińska, Kowalik, Gruszczyńska, Hościło, 2003). Na podstawie danych z satelitów Landsat, SPOT, NOAA/AVHRR i ERS-2.ATSR obliczono teledetekcyjne wskaźniki roślinności określające stopień rozwoju roślin i uwilgotnienie łąk. Wykonano klasyfikację łąk na obrazowych danych z Landsata i danych mikrofalowych ERS-2. Używając danych radarowych i wymienionych wskaźników określono wilgotność siedlisk. Następnie badano związek wartości LAI, które posłużyły do szacowania biomasy, ze wskaźnikami stopnia rozwoju roślin. Dla tych terenów opracowano ponadto metodę pozyskiwania parametru LAI, a tym samym monitoringu łąk (Budzyńska, Dąbrowska-Zielińska, Turlej, Małek, Bartold, 2011). Na podstawie obrazów satelitarnych przeprowadzono klasyfikację zbiorowisk roślinnych i obliczono teledetekcyjne wskaźniki roślinności i gęstość strumieni ciepła. Opracowano empirycznie zależność LAI od wskaźników roślinności i na tej podstawie obliczono wartości zmiennej biofizycznej na terenach bagien. Zastosowano także algorytmy do obliczania wilgotności gleby na podstawie obrazów mikrofalowych.

Najczęściej poruszonymi zagadnieniami w badaniach teledetekcyjnych łąk są określanie kondycji roślin i próby oszacowania parametrów roślinnych, takich jak powierzchnia projekcyjna liści i biomasa. Pozyskanie informacji o parametrach przestrzennych możliwe jest jedynie przez związek ze wskaźnikami obliczonymi na podstawie obrazów satelitarnych lub lotniczych. Konieczne jest także wykonanie jednoczesnych pomiarów terenowych, co znacznie wydłuża czas badań. Badania terenowe są szczególnie istotne w przypadku pozyskiwania informacji o zawartości biomasy.

Drugim sposobem badania roślinności metodami teledetekcyjnymi jest modelowanie z użyciem równania transferu promieniowania odbicia od liści i pokrywy roślinnej (Jacquemoud, Ustin, Verdebout, Schmuck, Anderoli, Hosgood, 1996). Modele transferu promieniowania umożliwiają bezpośrednie pozyskiwanie parametrów biofizycznych z danych teledetekcyjnych. Modele RTM są modelami fizyczno-matematycznymi, które na podstawie praw fizycznych opisują, co dzieje się z promieniowaniem w atmosferze i w kontakcie z pokrywą

roślinną. Modele opierają się na charakterystyce transferu energii w formie promieniowania elektromagnetycznego. Rozprzestrzenianie się promieniowania przez określone medium jest uwarunkowane procesami absorpcji, emisji i rozproszenia (Kumar, Schmidt, Dury, Skidmore, 2006).

Modele RTM są używane od kilkudziesięciu lat do symulowania pokrywy roślinnej, a po wykonaniu inwersji modelu do badania parametrów biofizycznych. Danymi wejściowymi są zmienne biofizyczne i biometryczne roślin, np. zawartość barwników, powierzchnia projekcyjna liści, zawartość wody, masy suchej, natomiast wyjściowymi krzywe odbicia spektralnego. Po dopasowaniu parametrów modelu i sprawdzeniu, czy możliwe jest uzyskanie prawidłowych krzywych odbicia spektralnego, przeprowadzana jest inwersja modelu. Wtedy do modelu są wczytywane dane spektrometryczne (terenowe, lotnicze lub satelitarne), a wynikiem są wybrane parametry biofizyczne i biometryczne. Przedstawiony sposób pozyskiwania tych parametrów jest bardziej wiarygodny niż metody statystyczne.

Dotychczas na terenie Polski modele transferu promieniowania nie były wykorzystywane do badań roślinności łąkowej. Na ogół modele RTM są używane do badania roślinności homogenicznej ze względu na konieczność uogólnienia budowy i ujednoczenia rozkładu substancji biofizycznych występujących w pokrywie roślinności. Łąki także w badaniach światowych są rzadko modelowane, co jest związane ze znacznym zróżnicowaniem wewnętrznym tego środowiska. Łąki na terenie Polski mają często charakter naturalny lub półnaturalny, tym samym są one bardziej zróżnicowane niż łąki uprawiane.

W znacznej części badań z użyciem tych modeli wykorzystuje się jedynie podstawowe badania terenowe wykonywane w trakcie zobrazowania. Część danych wejściowych jest uzyskiwana z poziomu naziemnego, część z pułapu lotniczego, a pozostałe są szacowane lub nadawane arbitralnie. Dlatego zastosowanie jednolitych badań terenowych zapewnia lepszą ocenę skuteczności modeli.

Monitoring łąk jest bardzo istotnym zagadnieniem. Bardzo wartościowe jest zastosowanie danych teledetekcyjnych, które umożliwiają wiarygodne pozyskiwanie informacji dla dużego terenu w znacznie krótszym czasie niż przy użyciu tradycyjnych metod badawczych. W przypadku badań klasycznych i teledetekcyjnych bardzo często poruszonym zagadnieniem jest szacowanie parametrów biofizycznych pozwalających na prognozowanie plonów. Przy wykorzystaniu danych teledetekcyjnych jedynie zastosowanie modeli transferu promieniowania pozwala bezpośrednio z danych spektrometrycznych uzyskać informacje o parametrach biofizycznych.

W pracy będzie sprawdzane, czy możliwe jest zastosowanie modeli transferu promieniowania do symulowania spektrum zróżnicowanej roślinności łąkowej, która występuje na obszarze Polski, i określenie, jakie czynniki mogą wpływać na skuteczność modelowania. Przy

pozytywnych wynikach będą możliwe dalsze badania, np. inwersja modeli, a także ich zastosowanie do obrazów z pułapu lotniczego i satelitarnego.

#### **Teledetekcyjny monitoring stanu roślinności**

*Vegetation monitoring using remote sensing*

#### **Hiperspektralne badania roślinności na świecie**

*Vegetation researches using hyperspectral data*

Dane hiperspektralne są przydatne do określania stanu i kondycji roślinności. Przedstawione zostaną przykłady zastosowań danych hiperspektralnych w badaniach roślinności, ze szczególnym uwzględnieniem obszarów łąkowych. Omówione będą zastosowania tych danych do monitorowania roślinności i jej stanu, do klasyfikacji terenu i w modelach określających parametry biofizycznych roślin, do określania rozwoju roślin i prognozowania plonów.

W Polsce po raz pierwszy lotnicze dane hiperspektralne ze skanera DAIS 7915 do monitorowania stanu roślinności w Tatrach wykorzystali B. Zagajewski, M. Sobczak, M. Wrzesień (2004) i M. Sobczak, A. Folbrier, A. Kozłowska, M. Krówczyńska, P. Pabjanek, M. Wrzesień i B. Zagajewski (2005). Na podstawie danych terenowych i lotniczych utworzyli oni biblioteki spektralne zbiorowisk roślinnych. Wykorzystując biofizyczne zmienne zmierzone w terenie, określono kondycję roślinności. Dane hiperspektralne były również używane do rozpoznania stanu roślinności na obszarze Beskidu Niskiego (Jarocińska, Zagajewski, 2008). W tym przypadku zastosowano je do obliczania teledetekcyjnych wskaźników roślinności: NDVI, SAVI, LAI i fAPAR. Korzystając z danych lotniczych i pomiarów terenowych M. Zwijacz-Kozica (2010) wykonała kartowanie stanu kosodrzewiny na obszarze Doliny Gąsienicowej w Tatrach. W badaniach tych określano rozkład wartości parametrów biometrycznych i kondycję zarośli kosodrzewiny.

Dane ze skanera DAIS 7915 wraz z pomiarami terenowymi zastosowano także do badania skażenia roślinności metalami ciężkimi (Zagajewski, Lechnio, Sobczak, 2007).

Dane hiperspektralne stosowano do badania różnic właściwości spektralnych pszenicy w zależności od nawożenia (Piekarczyk, Sulewska, 2010). Na podstawie tych badań z użyciem teledetekcyjnych wskaźników roślinności prognozowano następnie plony. Do monitorowania sosny zwyczajnej na obszarze Puszczy Niepołomickiej użyto obrazów ze skanera AISA (Wężyk, Wertz, Waloszek, 2003). Z połączenia obrazów hiperspektralnych i pomiarów laboratoryjnych uzyskano informacje na temat zawartości chlorofilu w igłach sosen. Ponadto dane hiperspektralne na terenie Polski były także stosowane w badaniach zawartości chlorofilu w wodach śródlądowych (Osińska-Skotak, 2009).

Znacznie szerzej na świecie do badania roślinności wykorzystuje się dane o wysokiej rozdzielczości spektralnej. Na obszarze Szwecji wykorzystano dane pozyskane



w pomiarach terenowych do wykrywania i określania stopnia zainfekowania pszenicy przez grzyby (Muhammed, Larsolle, 2003). Terenowe dane hiperspektralne były również używane na terenie USA do wykrywania infekcji ziemniaków (Zhang, Qin, Liu, Ustin, 2003).

Naziemne i lotnicze dane hiperspektralne często służyły do obliczania teledetekcyjnych wskaźników roślinności. Wskaźniki te łączą dane teledetekcyjne z biofizycznymi charakterystykami roślin (Jensen, 1983; Ustin, Roberts, Gamon, Asner, Green, 2004). Wskaźniki na podstawie danych hiperspektralnych znajdują zastosowanie w badaniu produkcji biomasy, przewidywaniu produktywności i prognozowaniu plonów (Haboudane, Miller, Pattey, Zarco-Tejada, Strachan, 2004; Ustin, Roberts, Gamon, Asner, Green, 2004). Wskaźniki bazujące na wąskich zakresach widma elektromagnetycznego pozwalają na badanie kondycji roślinności, a także zawartości poszczególnych substancji w roślinach.

Na podstawie wskaźników obliczonych z danych hiperspektralnych określano stan drzew cytrusowych (Ye, Sakai, Okamoto, Garciano, 2008); wykrywano uszkodzenia w uprawach bawełny (Yang, Everitt, Fernandez, 2010); skażenia metalami ciężkimi trzciny pospolitej w Chinach (Liu, Chen, Wua G., Wua W., 2010). Naziemne obrazy hiperspektralne wykorzystywano do badania stresu wodnego jabłoni, z użyciem wskaźników określających kondycję roślin, zawartość chlorofilu, ilość światła użytego w procesie fotosyntezy, zawartość suchej masy i wody (Kim, Glenn, Park, Ngugi, Lehman, 2011). W uprawach ryżu określano zawartość azotu i kondycję roślin (Tian, Yao, Yang, Cao, Hannaway, Zhu, 2011).

Obrazy hiperspektralne pozyskiwane z pułapu lotniczego w połączeniu z danymi naziemnymi były używane do identyfikowania gatunków drzew w obszarach Parku Narodowego Yellowstone w USA (Aspinall, 2002). Z użyciem laboratoryjnych danych hiperspektralnych odróżniano gatunki drzew w lasach namorzynowych (Vaiphasa C., Ongsomwang, Vaiphasa T., Skidmore, 2005).

Wśród badanych siedlisk analizowano także zbiorowiska trawiste. Na terenie pastwisk na wybrzeżu Morza Śródziemnego badano ilość biomasy i zawartość azotu za pomocą teledetekcyjnych wskaźników roślinności obliczonych z hiperspektralnych terenowych pomiarów spektrometrycznych (Fava, Colombo, Bocchi, Meroni, Sitzia, Fois, Zucca, 2009). Określano biofizyczne parametry roślin łąkowych na terenach objętych pożarem przy użyciu teledetekcyjnych wskaźników roślinności obliczonych z naziemnych danych spektrometrycznych (Rahman, Gamon, 2004). Wskaźniki wykorzystano także do badania stanu i rozwoju roślin łąkowych na terenie wyspy Horn w zatoce Meksykańskiej (Lucas, Carter, 2008). Hiperspektralne spektrometryczne dane naziemne używane były do badania trawników i boisk porośniętych trawą (Schut, Ketelaars, Meuleman, Kornet, Lokhorst, 2002). Dane ze spektrometru GER 3700 posłużyły do określania rozwoju traw w zależności od nawożenia (Mutanga, Skidmore, van Wieren, 2003). Badania przeprowadzono na poletkach testowych

w warunkach szklarniowych przy różnym nawożeniu azotem. Badano także zawartość azotu na obszarze sawann w Afryce z wykorzystaniem obrazu ze skanera hiperspektralnego HyMap (Mutanga, Skidmore, 2004).

Pomimo podobieństwa krzywej odbicia spektralnego wszystkich roślin, pojedyncze gatunki i zbiorowiska różnią się między sobą wielkością odbicia w wybranych zakresach. Jest to związane ze zróżnicowaną zawartością w roślinach poszczególnych pierwiastków, wody, a także różną ich budową. Dlatego dane hiperspektralne znajdują zastosowanie także w klasyfikacji zbiorowisk roślinnych.

W Polsce obrazy hiperspektralne ze skanera DAIS 7915 i ROSIS wykorzystywano do klasyfikacji roślinności z użyciem tradycyjnych klasyfikatorów oraz metodą sieci neuronowych. Badania takie prowadzono na obszarze górskim w Tatrach (Zagajewski, Kozłowska, Krówczyńska, Sobczak, Wrzesień, 2005; Zagajewski, 2010), a także w Beskidzie Niskim (Olesiuk, Zagajewski, 2008).

Podobne analizy przeprowadzono w okolicach Krakowa (Hejmanowska, 2007); klasyfikację form użytkowania terenu w tych okolicach na podstawie obrazu hiperspektralnego ze skanera Hyperion umieszczonego na satelicie EO-1 porównano z klasyfikacją wykonaną na obrazie wielospektralnym ze skanera ALI. Ponadto obrazy ze skanera Hyperion były wykorzystywane do klasyfikacji drzewostanów metodą *Spectral Angle Mapper* (Bartold, 2008).

Dane hiperspektralne były używane także do klasyfikowania zbiorowisk łąkowych. Za pomocą obrazu hiperspektralnego rozpoznawano łąkowe zbiorowiska roślinne w Bawarii (Schmidtlein, Sassin, 2004). Klasyfikacja obrazu HyMap była użyta do wykrywania wodnych roślin inwazyjnych w delcie rzeki San Joaquin i Sacramento w stanie Kalifornia w USA (Underwood, Mulitsch, Greenberg, Whiting, Ustin, Kefauver, 2006). Dane z lotniczego skanera CASI-2 posłużyły do klasyfikacji roślinności łąkowej metodą *Spectral Unmixing* w Kalifornii w USA (Miao, Gong, Swope, Pu, Carruthers, Anderson, Heaton, Tracy, 2006).

Wykorzystując dane hiperspektralne badano rodzaje łąk Japonii i występujące na nich gatunki roślin (Tomimatsu, Itano, 2009). Analizowano zmiany w wielkości odbicia w całym spektrum i w wartościach teledetekcyjnych wskaźników roślinności. Obrazy hiperspektralne wykorzystywano do klasyfikowania podmokłych łąk w Japonii pod kątem występowania gatunków zagrożonych (Ishii, Lu, Funakoshi, Shimizu, Omasa, Washitani, 2009). W czasie badań wyodrębniono różne rodzaje siedlisk łąkowych.

Dane hiperspektralne stosowano w badaniach parametrów biofizycznych roślin, a także do modelowania produktywności zbiorowisk roślinnych. Lotnicze obrazy hiperspektralne umożliwiły analizę właściwości i funkcjonowania ekosystemów, identyfikację gatunków, określanie zawartości pierwiastków chemicznych, badanie właściwości biogeochemicznych oraz procesu fotosyntezy (Ustin, Roberts, Gamon, Asner, Green, 2004). Używając tego typu danych, mierzono zawartość azotu w naziem-

nych częściach drzew w lesie i szacowano produktywność zbiorowiska (Smith, Ollinger, Martin, Aber, Hallett, Goodale, 2002).

Przewidywanie plonów jest zagadnieniem często poruszonym w badaniach teledetekcyjnych. Do szacowania wartości parametrów biofizycznych pastwisk była używana metoda z wykorzystaniem modeli PLS (Kawamura, Watanabe, Sakanoue, Inoue, 2008). Do kalibracji stosuje się różne zakresy widma. W badaniach wykorzystano krzywe odbicia spektralnego pozyskane z odpowiednich zakresów spektrum elektromagnetycznego zarejestrowanych spektrometrem ASD FieldSpec Pro FR.

Szacowano także ilość biomasy z pastwisk na podstawie danych zarejestrowanych spektrometrem ASD FieldSpec FR (Zhao, Starks, Brown, Phillips, Coleman, 2007). Obliczane wskaźniki korelowano z parametrami biofizycznymi charakteryzującymi biomasę. Ponadto na podstawie danych ze spektrometru obrazującego InSpec V10, określano zawartość poszczególnych pierwiastków w roślinności łąk (Suzuki, Tanaka, Kato, Okamoto, Kataoka, Shimada, Sugiura, Shima, 2008). Do prognozowania plonów i pozyskiwania parametrów biofizycznych są używane modele transferu promieniowania. Badania z zastosowaniem modeli zostaną przedstawione w dalszej części pracy.

Zaprezentowano przegląd prac, w których stosowano dane hiperspektralne w badaniach roślinności. Wysokorozdzielcze dane, zarówno obrazy jak i pomiary naziemne, mogą być z powodzeniem stosowane do monitorowania roślinności. Najczęściej w badaniach używa się zakresu widma optycznego od 0,35 do 2,5  $\mu\text{m}$ . Wartości odbicia o wysokiej rozdzielczości spektralnej pozwalają na pozyskiwanie bardziej szczegółowych informacji niż z danych wielospektralnych.

Dane hiperspektralne były używane do klasyfikacji obrazów, w tym do badania typów roślinności. Często stosuje się je do określania kondycji roślinności, określania stresu wodnego roślin i ich faz rozwoju. Z wykorzystaniem modeli możliwe jest rozpoznawanie struktury roślinności, powierzchni liści i prognozowanie ilości biomasy, a tym samym plonów. Określano też zawartość poszczególnych substancji w roślinach – barwników (w tym chlorofilu), wody, suchych części roślin (np. ligniny, celulozy). W badaniach brano pod uwagę różne typy roślinności: uprawy – zboża, rośliny okopowe i plantacje drzew, a także, choć nieco rzadziej, naturalne – łąki i lasy.

Dane hiperspektralne mogą być używane do obliczania teledetekcyjnych wskaźników roślinności i jako dane wejściowe do modeli. Przy pozyskiwaniu parametrów biofizycznych z pokrywy roślinnej bardzo przydatne są modele transferu promieniowania, za pomocą których można je wyliczać bezpośrednio z danych o wysokiej rozdzielczości spektralnej.

## Wykorzystanie modeli transferu promieniowania w badaniach roślinności

### *Application of Radiative Transfer Models in vegetation analysis*

Modele transferu promieniowania (*Radiative Transfer Model* – RTM) są modelami fizyczno-matematycznymi, które na podstawie praw fizycznych opisują, co dzieje się z promieniowaniem w atmosferze i w kontakcie z pokrywą roślinną. Modele te zawierają charakterystykę transferu energii w formie promieniowania elektromagnetycznego, a tym samym równanie transferu promieniowania.

Rozprzestrzenianie się promieniowania przez określone medium jest uwarunkowane procesami absorpcji, emisji i rozproszenia (Kumar, Schmidt, Dury, Skidmore, 2006). Promieniowanie elektromagnetyczne jest związane z czterema procesami: odbiciem, absorpcją, transmisją i rozproszeniem. Niezależnie od ośrodka, przez który przechodzi promieniowanie, do każdego z nich może być zastosowane równanie transferu promieniowania, które opisuje interakcje między obiektem a promieniowaniem. Na podstawie prawa Plancka można opisać promieniowanie słoneczne jako promieniowanie emitowane przez ciało doskonale czarne o temperaturze 6000 K. Energia słoneczna, która dociera do Ziemi po przejściu przez atmosferę, jest absorbowana i odbijana, co może być opisane przy wykorzystaniu prawa Stefana-Boltzmana.

Całe promieniowanie, mierzone przez sensor w zakresie optycznym, składa się z promieniowania odbitego od powierzchni, promieniowania rozproszonego przy powierzchni oraz promieniowania rozproszonego w atmosferze i od niej odbitego (Carli, 2006). Podstawowym procesem, który wpływa na osłabienie promieniowania w ośrodku, jest ekstynkcja, która obejmuje procesy absorpcji i rozpraszania. W czasie absorpcji fotony są pochłaniane, a w drugim procesie rozpraszane w sposób chaotyczny. Absorpcja jest określona przez współczynnik absorpcji i prawo Plancka. Jeśli właściwości fizyczne i optyczne ośrodka nie są stałe, to współczynnik absorpcji i temperatura lokalna zależą od miejsca w ośrodku. W przypadku ośrodków zróżnicowanych, jakim jest roślinność, konieczne jest uwzględnienie tego założenia, co bardzo utrudnia rozwiązanie równania. Ze względu na trudności w rozwiązaniu często dzieli się je na dwa składniki: promieniowanie bezpośrednie i rozproszone. Istnieje wiele metod rozwiązywania równania, na ogół jednak są to przybliżenia. Zawsze wtedy konieczne jest zdefiniowanie warunków brzegowych modelu.

Ośrodki takie jak atmosfera lub pokrywa roślinna są bardzo złożone. Równanie transferu promieniowania w tych ośrodkach musi uwzględniać ich zróżnicowanie. Dlatego nie może być stosowane tylko jedno równanie, ale ich zestaw, który jest nazywany modelem transferu promieniowania. Modele opisują, w jaki sposób promieniowanie jest odbijane, pochłaniane i rozpraszane przez ośrodek, przy uwzględnieniu jego specyfiki. Modele

transferu promieniowania są stosowane w teledetekcji środowiska do korekcy obrazów teledetekcyjnych oraz modelowania odbicia od liści i od pokrywy roślinnej.

Jak zostało wspomniane wcześniej, do badania właściwości pokrywy roślinnej używane są dwa podejścia: statystyczne i modelowanie (Jacquemoud, 1993; Kumar, Schmidt, Dury, Skidmore, 2006). Modelowanie odbicia w obrębie roślin wykorzystuje równania transferu promieniowania (RTM) (Jacquemoud, Ustin, Verdebout, Schmuck, Anderoli, Hosgood, 1996). W modelowaniu z użyciem RTM zbiorowiska roślinne lub pojedyncze rośliny są opisane jako jednorodne warstwy. Roślinność może być traktowana jako warstwa składająca się z liści i przestrzeni między nimi. Zarówno pojedyncze liście, jak i cały baldachim roślinności można opisać za pomocą trzech parametrów: odbicia, absorpcji i transmisji.

Modele transferu promieniowania mogą być dostosowywane do różnego typu powierzchni i warunków, ponieważ są w nich uwzględniane procesy fizyczne wyjaśniające wpływ parametrów biofizycznych na wielkość odbicia. Aby określić, w jaki sposób światło przechodzi przez liście, opracowano szereg modeli, które można podzielić na opisowe (*descriptive*) i bazujące na prawach fizycznych (*physically-based*) (Kumar, Schmidt, Dury, Skidmore, 2006).

Pierwsza grupa obejmuje modele używane w analizach teoretycznych. Ich największą wadą jest brak możliwości inwersji modelu, co uniemożliwia pozyskanie zmiennych biofizycznych z krzywych odbicia spektralnego.

Do drugiej grupy należą modele oparte na równaniu transferu promieniowania i teorii P. Kubelki i F. Munka (1931, za Abdul-Rahman, Chen, 2005) oraz modele określające roślinność jako płaskie płaszczyzny (*plate models*). Umożliwiają one przeprowadzanie procedur inwersyjnych.

Teoria Kubelki i Munka określa właściwości optyczne ośrodka oraz współczynniki absorpcji i rozproszenia (Kubelka, Munk, 1931, za Abdul-Rahman, Chen, 2005). Zakłada ona, że promieniowanie padające na powierzchnię obiektu może być rozproszone jedynie w dwóch kierunkach – w górę i w dół. Odbicie zależy od grubości ośrodka, współczynników odbicia i rozproszenia oraz odbicia od tła. W teorii liść jest opisany jako warstwa materiału absorbującego i rozpraszającego (Kumar, Schmidt, Dury, Skidmore, 2006). Modele tego typu są najbardziej skuteczne w przypadku, gdy padający strumień promieniowania jest jednolicie rozpraszany we wszystkich kierunkach. Modele te były rozwijane do lat 60. XX wieku. Początkowo nie brano w nich pod uwagę zmienności promieniowania w obrębie pokrywy roślinnej, co było związane z nieuwzględnieniem różnych kątów padania promieni słonecznych. W latach 70. zaproponowano bardziej złożone modele, uwzględniające obecność kwiatów i gałęzi. Rozwinięciem tych modeli jest model SAIL, który uwzględnia także różnorodne rozmieszczenie liści (Verhoef, 1984).

Model typu *plate* traktuje liście jak płaskie struktury.

W modelu opisywane jest odbicie i rozproszenie promieniowania. W pierwszych modelach liść był opisywany jako jedna warstwa o danych współczynnikach załamania i absorpcji. W kolejnych, zostały uwzględnione także powietrze między warstwami liści. Aby polepszyć rezultaty, używając wypreparowanych liści, ustalono specyficzne współczynniki absorpcji wody, pigmentów nefotosyntetyzujących i chlorofilu. W ten sposób opracowano model PROSPECT (Jacquemoud, Baret, 1990).

W większość modeli zakłada się jednakowe we wszystkich kierunkach odbicie i transmisję od igieł i liści oraz od gleby (Verhoef, Bach, 2007). Wszystkie fragmenty pokrywy roślinnej i gleba powinny być jednorodne. Natomiast wszelkie elementy takie jak korzenie, gałęzie, kwiaty nie są uwzględniane. Ponadto model nie może zawierać zbyt wielu parametrów wejściowych, ponieważ niemożliwa byłaby jego inwersja.

Modele charakteryzujące roślinność różnią się danymi wejściowymi i wyjściowymi, poziomem analizy, wprowadzanymi modyfikacjami uwzględniającymi zakłócenia i rodzajem roślinności, do jakiego można je zastosować. Parametrami wejściowymi modeli są zmienne biofizyczne (np. zawartość chlorofilu, wody, biomasa, geometria pokrywy roślinnej, liści), a wyjściowymi na ogół krzywe odbicia spektralnego. Modele mogą dotyczyć roślinności na dwóch poziomach: pokrywy roślinnej i liści. Dane wyjściowe z modeli opisujących rośliny na poziomie pojedynczych liści są często wykorzystywane jako dane wejściowe do modeli pokrywy roślinnej. RTM mogą uwzględniać różnego rodzaju zakłócenia przez wprowadzanie elementów korygujących, np. usuwające efekt nadmiernego odbicia (*hot spot*). Są dostosowywane do wykorzystania przy badaniu różnych powierzchni, takich jak łąki i lasy.

Modele transferu promieniowania są coraz szerzej stosowane w badaniach roślinności. Wynika to z automatyzacji procesu inwersji modeli na podstawie danych hiperspektralnych.

W Polsce badania roślinności, wykorzystujące dane zarówno wielospektralne jak i hiperspektralne, do tej pory odbywały się wyłącznie przy użyciu podejścia statystycznego, (np. Dąbrowska-Zielińska, Budzyńska, Lewiński, Hościło, Bojanowski, 2009). RTM mogą być używane do symulowania pomiarów spektrometrycznych, a także, po przeprowadzeniu inwersji, do pozyskiwania parametrów biofizycznych z krzywych odbicia spektralnego. Pozyskiwanie parametrów biofizycznych z danych hiperspektralnych polega na odwróceniu modelu tak, aby na wyjściu były zmienne biofizyczne. Duża liczba danych wejściowych do modelu utrudnia jego dalsze przekształcenia, a tym samym użytkowanie modelu. Skuteczność inwersji zależy do wielu czynników: od ilości informacji użytej w badaniach, czyli od ilości krzywych odbicia spektralnego wykorzystanych do inwersji; od jakości danych spektrometrycznych, czyli od rozdzielczości radiometrycznej, spektralnej, ilości zakłóceń; od wybrania odpowiedniego modelu, który jest dostosowany do struktury roślin oraz od samej inwersji – jej rodzaju i założonych zmiennych biofizycznych

(Weiss, Baret, Myneni, Pragnère, Knyazikhin, 2000). Powyższe informacje wskazują, że istotnym aspektem badań jest wybór modelu, a także jego dopasowanie do środowiska na podstawie danych dobrej jakości.

### **Modelowanie roślinności na poziomie pojedynczych liści**

#### *Vegetation modelling on leaf level*

Modele RTM, które opisują roślinność na poziomie liści i charakteryzują wielokierunkowe odbicie i rozproszenie, najczęściej należą do kategorii *plate models*. Definiują one wewnętrzną strukturę rośliny jako płaszczyznę złożoną z liści i powietrza, nie uwzględniają atmosfery (Kumar, Schmidt, Dury, Skidmore, 2006).

Model LIBERTY jest przeznaczony do charakteryzacji igieł drzew iglastych, w szczególności sosny (Dawson, Curran, Plummer, 1999). Może on być używany do badań laboratoryjnych i terenowych. Uwzględnia zawartość chlorofilu, wody, celulozy, ligniny i białka mierzonych na jednostkę powierzchni. Określane są także parametry strukturalne, takie jak średnica komórki, grubość igieł i międzykomórkowe przestrzenie powietrzne. Model oblicza odbicie i transmitancję w przypadku pojedynczych igieł i pęków.

Innym modelem jest model LEAFMOD – *Leaf Experimental Absorptivity Feasibility MODEL*, który bardzo upraszczając, dobrze symuluje rośliny iglaste (Ganapol, Johnson, Hammer, Hlavka, Peterson, 1998).

Do modelowania liści najczęściej jest używany model PROSPECT, który został zastosowany w niniejszym badaniach (Jacquemoud, Baret, 1990). Jest on jednym z najpopularniejszych na świecie modeli obliczających charakterystyki spektralne roślin (Jacquemoud, Ustin, Verdebout, Schmuck, Anderoli, Hosgood, 1996; Jacquemoud, Bacour, Poilvé, Frangi, 2000; Haboudane, Miller, Tremblay, Zarco-Tejada, Dextraze, 2002; Verhoef, Bach, 2003; Feret, François, Asner, Gitelson, Martin, Bidet, Ustin, le Maire, Jacquemoud, 2008; Darvishzadeh, Skidmore, Atzberger, van Wieren, 2008). Charakteryzuje się niewielką liczbą parametrów wejściowych, jest dość prosty w zastosowaniu, a jednocześnie efektywny. Na ogół jest stosowany do jednolitych powierzchni, takich jak zboża. Z czasem zaczęto wprowadzać modyfikacje modelu umożliwiające badanie bardziej złożonych formacji roślinnych. Model ten bardzo rzadko jest stosowany do roślinności niejednorodnej. Używany on jest jako samodzielny moduł lub jako kombinacja z innymi algorytmami charakteryzującymi cały baldachim roślinności.

Samodzielnie model PROSPECT był stosowany do celów aplikacyjnych w badaniach parametrów biofizycznych na poziomie pojedynczych liści, w szczególności zawartości chlorofilu (Feret, François, Asner, Gitelson, Martin, Bidet, Ustin, le Maire, 2008) i wody (Ceccato, Flasse, Tarantola, Jacquemoud, Grégoire, 2001). Użyto go do badania zawartości chlorofilu w igłach w lasach sosnowych na terenie Kanady (Zarco-Tejada, Miller, Harron, Hu, Noland, Goel, Mohammed, Sampson, 2004).

W badaniach tych wykonywano pomiary laboratoryjne i terenowe, a także zobrazowanie z wykorzystaniem skanera CASI. Dokonano inwersji modelu, aby uzyskać parametry biofizyczne na poziomie pojedynczych igieł.

Badano możliwości modelu w zakresie symulowania danych opisujących roślinność, szczególnie hiperspektralnych (Jacquemoud, Baret, 1990; Jacquemoud, Ustin, Verdebout, Schmuck, Anderoli, Hosgood, 1996) i analizowano wartości współczynnika absorpcji w zakresie poszczególnych długości fali (Fourty, Baret, Jacquemoud, Schmuck, Verdebout, 1996).

Najczęściej wykorzystywany jest jako model obliczający parametry wejściowe do innych modeli. Może być łączony z modelami rolniczymi, czyli szacującymi rozwój roślin i plony (Blackburn, Ferwerda, 2008), a także z innymi modelami transferu promieniowania opisującymi pokrywę roślinną. Bez połączenia z modelem opisującym pokrywę roślinności może być zastosowany jedynie używając danych pobranych na poziomie naziemnym. Szczegółowe wykorzystanie modelu PROSPECT razem z modelem SAIL i jego odmianami będzie przedstawione w dalszej części pracy.

### **Modelowanie roślinności na poziomie pokrywy roślinności**

#### *Vegetation modelling on canopy level*

Druga kategoria modeli to modele opisujące pokrywę roślinną. W zbiorowiskach roślinnych promieniowanie odbijane jest zarówno od samej roślinności, zwłaszcza liści, a także od gleby, czyli tła, oraz od niezielonych elementów roślin, takich jak gałęzie, kwiaty, które wpływają na wielkość odbicia (Verhoef, Bach, 2003). Poza tym liście są zacienione w znacznym stopniu przez inne liście i odbicie od liści osłoniętych jest inne niż od odsłoniętych. Na przykład, w rejonach wysokiej absorpcji odbicie może być znacznie mniejsze niż od pojedynczego liścia ze względu na zacienienie. Ponadto wewnątrz baldachimu roślinności zachodzi wielokrotne odbicie wiązki promieniowania od pojedynczych liści, które nie występuje w przypadku modelowania odbicia od pojedynczych liści.

Należy zwrócić uwagę na fakt dużej różnorodności modeli transferu promieniowania od całych zbiorowisk roślinnych. Jest to związane z różnorodnością ekosystemów roślinnych. W zależności od badanego środowiska w modelach wprowadzane są modyfikacje ułatwiające naśladowanie rzeczywistych warunków.

Wśród modeli opisujących pokrywę roślinną najbardziej popularny jest SAIL i jego modyfikacje. Jedną z nich została wybrana do zastosowania w tym opracowaniu – 4SAIL. Model SAIL (*Scattering by Arbitrarily Inclined Leaves*) jest jednowymiarowy, pod względem obliczeniowym mało wymagający, z niewielką liczbą parametrów wejściowych (Verhoef, 1984; 1985). Służy do opisu struktur baldachimu roślinności. Model ma wiele odmian: GeoSAIL, 2M-SAIL, SAILH, 4SAIL, GeoSail, 4SAIL2, FLSAIL, FluorSAIL (Verhoef, 1984; Verhoef,

Bach, 2007).

Model SAIL opracowany przez Vouta Verhoefa (1984, 1985) jest modelem najprostszym, na którym bazują pozostałe. W modelu uwzględnia się jedną warstwę roślinności, bez korekcji efektu *hot spot*, a także bez automatycznego usuwania błędów i niewłaściwych wartości (Verhoef, Bach, 2007). W działaniu (obliczeniach) jest dość powolny.

Jedną z pierwszych modyfikacji jest SAILH, który uwzględnia efekt nadmiernego odbicia (Kuusk, 1994). Efekt *hot spot* jest korygowany przez wprowadzenie parametru, który porównuje rozmiar liści do średniej wysokości pokrywy roślinności. Model opisuje roślinność jako jedną warstwę. Warstwa jest nieskończenie długa, a jej granice są równoległe. Model jest dość prosty i dość często stosowany wraz z PROSPECT. Służy do opisywania poziomo jednorodnej roślinności (Haboudane, Miller, Tremblay, Zarco-Tejada, Dextraze, 2002).

Kolejną modyfikacją jest GeoSAIL, który jest dwuwarstwową wersją SAIL (Verhoef, Bach, 2003). Służy do opisywania roślinności zróżnicowanej pionowo, wielowarstwowej (Jacquemoud, Verhoef, Baret, Bacour, Zarco-Tejada, Asner, François, Ustin, 2009). Jest on kombinacją modelu SAIL z podejściem geometrycznym (Verhoef, Bach, 2003). Poza samym modelem SAIL uwzględnia także efekt nadmiernego odbicia (*hot spot*). W modelu zakłada się, że w obu warstwach funkcja określająca nachylenie liści (*Leaf Inclination Distribution Function*) i rozmiar efektu *hot spot* są takie same. W modelu wprowadzona jest modyfikacja określająca zawartość wysuszonych liści. Ponadto model zawiera podprogram opisujący odbicie od gleby, który uwzględnia wilgotność gleby i jej wpływ na odbicie od górnej warstwy gleby.

Zbliżonym modelem do GeoSAIL jest 2M-SAIL (Weiss, Troufleau, Baret, Chauki, Prévot, Olivoso, Bruquier, Brisson, 2001). W modelu znacznie dokładniej opisana jest struktura roślinności przez nachylenie liści. Jest on określony jako model wielowarstwowy. Kolejna wersja modelu SAIL++ także wprowadza korekcję efektu *hot spot* (Verhoef, 2002). Model ten jest także bardziej precyzyjny obliczeniowo niż poprzednie wersje algorytmu. Następny model 4SAIL jest szybszy w działaniu operacyjnym i dokładniejszy niż poprzednie (Verhoef, Jia, Xiao, Su, 2007). Także uwzględnia efekt nadmiernego odbicia. Ma również wprowadzoną aplikację termalną – modelującą promieniowanie termalne.

Model GeoSail powstał do opisywania roślinności nieciągłej poziomo (Huemmrich, 2001). Model składa się z modelu SAIL i programu modelującego bardziej zróżnicowaną powierzchnię, np. lasów. Kolejny model do opisania roślinności zróżnicowanej poziomo to dwuwarstwowy, czterostrumieniowy 4SAIL2 (Verhoef, Bach, 2007). W modelu uwzględnia się kształt koron drzew, a także inne niż idealnie rozproszone odbicie od gleby. Najpierw obliczane są charakterystyki wyizolowanej dolnej warstwy roślinności, następnie dodawane dane dla warstwy górnej i w końcu obliczone są łączne właściwości całej warstwy. Następnie zastosowany jest

moduł, który modyfikuje odbicie ze względu na to, że korony drzew nie są płaszczyzną, tylko stanowią sferyczne uwypuklenia. 4SAIL2 uwzględnia udział suchych i zielonych liści.

Do modelowania pokrywy roślinnej są wykorzystywane także inne modele, geometryczno-optyczne, które również można poddawać inwersji. Model, który jest dostosowany do złożonych i zróżnicowanych ekosystemów, to model *Forest LIGHT Interaction Model – FLIGHT* (North, 1996). Jest to model trójwymiarowy, w odróżnieniu od modelu jednowymiarowego, jakim jest SAIL. W połączeniu z modelem LIBERTY uwzględniają między innymi LAI, zwartość pokrywy, odbicie na poziomie liści, zawartość wody i ligniny lub celulozy. Model umożliwia obrazowanie złożonych struktur i wielokrotnego odbicia na terenie lasów iglastych, ponieważ uwzględniana jest zmienność każdej korony drzewa. Wykorzystywany był między innymi do porównywania wartości wskaźników roślinności na terenie lasów iglastych południowo-wschodniej Szwajcarii (Verrelst, Jia, Xiao, Su, 2008).

Do tego samego środowiska dostosowany jest model RSADU (Kumar, Schmidt, Dury, Skidmore, 2006). W modelu LCM2 – *Leaf/Canopy Model* uwzględnia się biochemię i morfologię liści, ich grubość, odbicie od tła gleby oraz budowę pokrywy roślinnej (Ganapol, Johnson, Hlavka, Peterson, Bond, 1999). Powstały także inne modele opisujące roślinność – KUUSK, IAPI i NADI (Bacour, Jacquemoud, Tourbier, Dechambre, Frangi, 2002).

Kolejnym modelem charakteryzującym pokrywę roślinności jest ACRM, dostosowany do roślinności jednorodnej (Weihs, Suppan, Richter, Petritsch, Hasebauer, Schneider, 2008). W modelu uwzględnia się dwie warstwy roślinności. Danymi wejściowymi są: LAI, kąt nachylenia liści, rozmiar liści, biochemiczne parametry liścia i odbicie od gleby. Łączony jest z modelem PROSPECT, który dostarcza informacji o biochemicznych właściwościach liści.

Modele dotyczące szaty roślinnej, ze względu na trudności w przeprowadzeniu inwersji, są rzadko używane bez modeli opisujących pojedyncze liście. W przypadku SAIL są trzy zmienne wejściowe, które zależą od długości fali elektromagnetycznej: odbicie od liści, transmitancja przez liście i odbicie od gleby. Trudno jest uzyskać dane po inwersji, gdy trzy z nich są zależne od długości fali (Verstraete, Pinty, 2001). Odwrócenie samego modelu na poziomie szaty roślinnej – SAIL wymaga posiadania danych z różnych kątów obserwacji (Jacquemoud, Verhoef, Baret, Bacour, Zarco-Tejada, Asner, François, Ustin, 2009). W praktyce procedura ta jest czasochłonna i niepraktyczna, dlatego łączy się modele opisujące całą pokrywę roślinną z modelami dotyczącymi odbicia od pojedynczych liści.

Jednym z najczęstszych połączeń jest kombinacja modelu PROSPECT opisującego odbicie na poziomie liści z SAIL na poziomie pokrywy (Kumar, Schmidt, Dury, Skidmore, 2006; Jacquemoud, Verhoef, Baret, Bacour, Zarco-Tejada, Asner, François, Ustin, 2009; Verhoef, Bach, 2003). Tego typu kombinacje mają dużo

danych wejściowych, natomiast nie są brane pod uwagę niektóre zmienne opisujące pokrywę roślinną. Duża liczba zmiennych może powodować trudności w przeprowadzaniu inwersji.

Kombinacja modelu PROSPECT i SAIL nazywana jest PROSAIL. Model ten był używany do badania wielu zbiorowisk roślinnych: buraków cukrowych, ziemniaków, zbóż, w tym pszenicy, kukurydzy, lasów, w tym konkretnych gatunków drzew: buka, dębu, klonu cukrowego, plantacji oliwek, a także zbiorowisk trawiastych (Jacquemoud, Verhoef, Baret, Bacour, Zarco-Tejada, Asner, François, Ustin, 2009). W badaniach stosowano naziemne dane ze spektrometrów ASD, GER i innych, a także obrazów ze skanerów lotniczych: DASI, CASI, POLDER oraz skanerów satelitarnych: HYPERION, MERIS, MODIS i innych. Model często był stosowany do pozyskiwania parametrów biofizycznych roślinności po przeprowadzeniu inwersji. Najczęściej badano cechy, które mają ścisły związek z kondycją roślinności, a także ilością biomasy, czyli zawartość chlorofilu i wielkość powierzchni projekcyjnej liści – LAI.

Już w połowie lat 90. XX wieku jedna z modyfikacji modelu SAIL – SAILH, w połączeniu z PROSPECT była stosowana do symulacji krzywych odbicia spektralnego od buraków cukrowych (Jacquemoud, Baret, Andrieu, Danson, Jaggard, 1995). W badaniach została opracowana procedura inwersji połączonego modelu korzystającego z danych zebranych w terenie, dotyczących zawartości chlorofilu, wody i LAI. W przypadku tego samego środowiska symulowano krzywe odbicia spektralnego (Andrieu, Baret, Jacquemoud, Malthus, Steven, 1997). Autorzy zajmowali się dopasowywaniem parametrów wejściowych odpowiednich do danego typu roślinności, szczególnie tych, które nie są możliwe do zmierzenia w terenie. W badaniach buraków cukrowych porównywano także skuteczność modelowania z użyciem PROSAIL w zależności od sposobu pozyskiwania parametrów wejściowych (Duke, Guérif, 1998).

Badano skuteczność 4 różnych modeli: SAILH, IAPI, KUUSK i NADI w połączeniu z modelem PROSPECT do określania parametrów biofizycznych upraw kukurydzy i soi (Jacquemoud, Bacour, Poilvé, Frangi, 2000). Najlepsze wyniki uzyskiwano w przypadku modeli SAILH i KUUSK.

Model PROSPECT w połączeniu z SAILH (modyfikacją SAIL) po inwersji był używany do szacowania zawartości chlorofilu w zbożach (Haboudane, Miller, Tremblay, Zarco-Tejada, Dextraze, 2002) oraz w plantacjach drzew oliwnych (Zarco-Tejada, Miller, Morales, Berjón, Agüera, 2004). Oba modele stosowano do określania zawartości wody w roślinach (Zarco-Tejada, Rueda, Ustin, 2003). Zawartość wody w roślinach określono na podstawie pomiarów terenowych. Używając charakterystyk spektralnych, otrzymanych ze skanera MODIS, wykonano inwersję modelu. Z przeprowadzonej procedury uzyskano parametry strukturalne liści, ilość masy suchej roślin i zawartość wody w roślinach, którą porównano z danymi terenowymi.

Stosując w wymienionych modelach dane hiperspek-

tralne ze skanera CASI szacowano wartość LAI do celów rolnictwa precyzyjnego na podstawie teledetekcyjnych wskaźników roślinności w przypadku upraw: kukurydzy, pszenicy i soi (Haboudane, Miller, Patten, Zarco-Tejada, Strachan, 2004). Wielkość LAI szacowano także z użyciem modelu SAIL i PROSPECT na obszarze plantacji topoli (Meroni, Colombo, Panigada, 2004) i kukurydzy (Koetz, Baret, Poilvé, Hill, 2005). Modele PROSPECT i SAIL wraz z modelem odbicia od gleby posłużyły do pozyskiwania wartości LAI, które były użyte do monitorowania wzrostu pszenicy i szacowania plonów (Migdall, Bach, Bobert, Wehrhan, Mauser, 2009). Modeli RTM używano w badaniach stresu wodnego na obszarze południowej Hiszpanii (Suárez, Zarco-Tejada, Berni, Gonzáles-Dugo, Fereres, 2009). Modele PROSPECT razem z SAILH posłużyły do symulowania odbicia od kukurydzy, a z modelem FLIGHT 3D do opisywania drzew oliwnych i brzoskwini, a następnie określania parametrów roślin.

Poza modelem SAILH używane są też inne modele z tej grupy. Model 2M-SAIL był stosowany do modelowania odbicia spektralnego zbóż (Weiss, Troufleau, Baret, Chauki, Prévot, Oliso, Bruguier, Brisson, 2001). Modele GeoSail używano głównie do modelowania charakterystyk spektralnych lasów, np. razem z PROSPECT do określania zagrożenia pożarowego na terenie Szwajcarskiego Parku Narodowego (Köts, Schaepman, Morsdorf, Bowyer, Itten, Allgöwer, 2004). Modeli tych używano do pozyskiwania parametrów biofizycznych i określania kondycji lasów na terenie Szwajcarii. Korzystano w tym przypadku z danych terenowych oraz danych ze skanerów DAIS 7915 i HyMap (Schaepman, Koetz, Schaepman-Strub, Itten, 2005). Model 4SAIL2 był stosowany do badania plantacji eukaliptusa (le Maire, Marsden, Verhoef, Ponzoni, Seen, Bégué, Stape, Nouvelon, 2011). Po przeprowadzeniu inwersji, na podstawie danych wieloczasowych, był używany do pozyskiwania wartości LAI.

Kolejne badania dotyczyły technicznych aspektów tworzenia modeli lub przeprowadzania inwersji. Badano skuteczność inwersji modeli PROSPECT i SAIL na podstawie danych z sensora AVIRIS (Jacquemoud, 1993). Najlepsze wyniki inwersji uzyskano w przypadku parametrów biofizycznych liści – zawartości wody i chlorofilu, nieco gorsze w odniesieniu do parametrów określających budowę baldachimu roślinności – LAI i średniego kąta nachylenia liści, najgorsze natomiast w przypadku wskaźnika opisującego promieniowanie wykorzystywane w procesie fotosyntezy (APAR).

Przeprowadzono badania nowego sposobu inwersji modelu PROSPECT i SAILH opartego na metodzie segmentacji (Atzberger, 2004). Badano efektywny sposób przeprowadzania inwersji z użyciem *look-up tables* na modelach PROSPECT, PROSAIL i DART (Hedley, Roeslfsma, Phinn, 2009). Sposoby przeprowadzania inwersji na obszarze jednorodnych upraw jęczmienia były badane z użyciem PROSAIL na podstawie danych lotniczych ze skanera HyMap (Vohland, Mader, Dorigo, 2010). Analizowano także różne możliwości tej procedury do

pozyskiwania zmiennych biofizycznych z upraw kukurydzy (Combal, Baret, Weiss, Trubuil, Macé, Pragnère, Myneni, Knyazikhin, Wang, 2002).

Modele bardzo rzadko były stosowane do opisywania zróżnicowanych zbiorowisk łąkowych. Modele PROSPECT i SAIL były użyte do badania parametrów biofizycznych i geometrii odbicia promieniowania na preriach z wysokimi trawami na obszarze stanu Kansas (Gao, Lesht, 1997). Model PROSAIL, złożony z modelu PROSPECT i SAILH, był stosowany do wyznaczania wartości chlorofilu i parametru LAI na zróżnicowanej roślinności łąkowej na obszarze Parku Narodowego Majella w Abruzji we Włoszech (Darvishzadeh, Skidmore, Schlerf, Atzberger, 2008). Modele transferu promieniowania z wykorzystaniem danych hiperspektralnych terenowych i lotniczych ze skanera HyMap posłużyły do modelowania LAI na obszarze zbiorowisk trawiastych w krajach śródziemnomorskich (Darvishzadeh, Atzberger, Skidmore, Schlerf, 2011). Do szacowania tego samego parametru biofizycznego używany był PROSAIL na obszarze pól suchych stepów w Chinach (Zhang, Zhao, 2009).

Połączenie modelu PROSPECT i SAILH było wykorzystane do szacowania wilgotności łąk i badania zagrożenia pożarowego (Yerba, Chuvieco, Riaño, 2008). Teren badań obejmował łąki i zarośla na obszarach suchych w krajach śródziemnomorskich. Modele były stosowane do symulacji krzywych odbicia spektralnego na podstawie danych terenowych. Używając ich, obliczono teledetekcyjne wskaźniki roślinności. Ten sposób postępowania porównano z wynikami uzyskanym z obrazów MODIS. Te same dwa modele wykorzystano do pozyskiwania informacji o zawartości wody w roślinach (Clevers, Kooistra, Schaepman, 2010). Badano dwa obszary Holandii – łąki zalewane z roślinnością naturalną i ekstensywnie wypasane podmokłe pastwiska. W badaniach model PROSAIL był stosowany do symulacji danych spektrometrycznych, a następnie do kalibracji wskaźnika wilgotności do rzeczywistej zawartości wody w roślinach.

W przeglądzie badań przedstawiono modele transferu promieniowania używane do badań roślinności. Najbardziej popularnym modelem, za pomocą którego możliwe jest obliczenie wielkości odbicia od pojedynczych liści, jest PROSPECT. Na poziomie pokrywy roślinnej bardzo często używane są modele z grupy SAIL, szczególnie wersja SAILH. W opisie nie uwzględniono wszystkich modeli, szczególnie w przypadku modeli opisujących roślinność na poziomie baldachimu. Skupiono się jedynie na analizie algorytmów z grupy SAIL oraz tych, które są najbardziej popularne, a także na wykorzystaniu RTM do badań zbiorowisk trawiastych. Przytoczone badania są jedynie przykładami zastosowań.

Na ogół modele RTM są używane do badania roślinności jednorodnej. Modele PROSPECT jak i SAIL są rzadko stosowane do modelowania odbicia od roślinności łąkowej. Jest to związane ze znacznym zróżnicowaniem wewnętrznym tego środowiska, co sprawia, że wyniki uzyskiwane za pomocą tych modeli są mało

dokładne. Ponadto w znacznej części badań z użyciem modeli wykorzystuje się jedynie podstawowe badania terenowe wykonywane w trakcie rejestracji obrazów lotniczych bądź satelitarnych. Część z nich pozyskiwana jest z poziomu naziemnego, a część z pułapu lotniczego. Takie postępowanie może prowadzić do zwiększenia błędów modelowania. Dlatego przeprowadzenie jednolitych badań terenowych, gdzie wszystkie dane dla badanych parametrów są pobierane w tym samym czasie, powinno przyczynić się do zwiększenia dokładności modelowania.

### **Charakterystyka środowiska badanych terenów** *Environmental characteristics of studied areas*

Do prowadzonych badań wytypowano dwa obszary, różniące się warunkami środowiska geograficznego.

Jednym z nich są tereny Pogórza Karpackiego znajdujące się w pobliżu Gorlic (ryc. 1). Pod względem regionalnym znajduje się on na terenie mikroregionu Pogórza Gorlickiego – 14.1.17, na pograniczu z Beskidem Magurskim – 14.2.14 (Olędzki, 2007). W dalszych częściach opracowania będą one określane jako tereny lub poligony pogórskie.

Drugim obszarem badań były poligony położone w obrębie Równin Środkowopolskich (ryc. 2). Tereny badawcze znajdowały się w pobliżu Warszawy. Pod względem regionalnym zaliczone zostały do Mazowsza Północnego (5.6), mikroregionu Ziemi Zakroczymsko-Serockiej (5.6.4); Doliny Środkowej Wisły (5.7) – mikroregionów: Nadzalewowych Tarasów Dęblińsko-Markoskich (5.7.3) i Rynny Karczewskiej (5.7.4) oraz Mazowsza Środkowego (5.10), mikroregionu Równiny Mszczonowskiej (5.10.11) (Olędzki, 2007). W dalszej części opracowania tereny te będą nazwane Mazowszem, terenami równinnymi bądź nizinnymi.

Pogórskie tereny pomiarowe zostały zlokalizowane w obrębie garbu pogórskiego Taborówki (3 poligony – oznaczone w opisach literą T), w dolinie Bystrzanki w pobliżu jej ujścia do Ropy oraz na stokach Wiatrówek (4 poligony – oznaczone literą P). Zbiorowiska łąkowe na terenach pomiarowych były złożone z co najmniej czterech gatunków roślin. W większości były to łąki rajgrasowe, wykształcone na siedliskach świeżych. Dominowały rośliny z rodziny wiechlinowatych: rajgras (w tym rajgras wyniosły – *Arrhenatherum elatius*), stokłosa (w tym stokłosa bezostna – *Bromus inermis*), a także perz właściwy (*Elymus repens*) i wiechlina łąkowa (*Poa pratensis*). Spoza rodziny wiechlinowatych duży udział miała koniczyna łąkowa (*Trifolium pratense*).

Badane łąki na Mazowszu można również określić jako zróżnicowane pod względem struktury – na ogół porastały je przynajmniej 4 różne gatunki roślin. Dominowały gatunki z rodziny wiechlinowatych: miętlica pospolita (*Agrostis capillaris*), kupkówka pospolita (*Dactylis glomerata*), tymotka łąkowa (*Phleum pratense*), wiechlina zwyczajna (*Poa trivialis*). Ponadto poza trawami występowały rośliny o liściach innej budowy –



Ryc. 1. Lokalizacja poligonów pomiarowych na Pogórzu Karpackim. Dolna część zlewni Bystrzanki. Zdjęcie wykonane 14 lipca 2009 roku o godzinie 14:39. Foto. J. R. Olędzki

Fig. 1. Localization of research polygons in Carpathian Mountains; Bystrzanka catchment. Photography: J. R. Olędzki (14.07.2009, 14:39)


motylkowe (np. koniczyna łąkowa – *Trifolium pratense*) oraz zioła i chwasty, np. babka lancetowata (*Plantago lanceolata*) i zwyczajna (*Plantago maior*), szczaw zwyczajny (*Rumex acetosa*). Część z wymienionych gatunków roślin, jak tymotka łąkowa, świadczy o tym, że łąki są użytkowane ekstensywnie (Kucharski, 2009).

Jak wspomniano, pomiary terenowe w obrębie Równin Środkowopolskich odbywały się na terenie trzech mikroregionów. Wyodrębniono tu 50 poligonów pomiarowych.

Na terenie Ziemi Zakroczymsko-Serockiej (5.6.4)

wyznaczono 16 poligonów – oznaczonych symbolem S (Olędzki, 2007). Pomiary wykonywano 4, 17 i 26 sierpnia 2010. Na Mazowszu Środkowym (5.10) – Równinie Mszczonowskiej (5.10.11) wyróżniono 29 poligonów pomiarowych i oznaczono literą R. Pomiary wykonywano w lipcu 2010 roku. W obrębie Doliny Środkowej Wisły wyróżniono 5 poligonów pomiarowych, oznaczonych literą D. Jeden poligon – D1, znajdował się na obszarze Rynny Karczewskiej (5.7.4), użytkowanej głównie jako użytki zielone (Olędzki, 2007). Pozostałe 4 poligony znajdowały





Ryc. 2. Rozmieszczenie obszarów badawczych z poligonami pomiarowymi na terenie Równin Środkowopolskich (D – Dolina Środkowej Wisły, S – Ziemia Zakroczymsko-Serocka, R – Równina Mszczonowska). W podkładzie obraz zaczerpnięty z Geoportalu Fig. 2. Study area with research polygons in Mazowsze Plain (D – Middle Vistula Valley, S – Zakroczymsko-Serocka Land, R – Mszczonowska Plain). Photo from Geoportal

się na Nadzalewowych Tarasach Dęblińsko-Markoskich (5.7.3). Pomiary terenowe na obu mikroregionach odbywały się 12 sierpnia 2010 roku.

Przedmiotem badań są zbiorowiska trawiaste. Łąki tworzone są głównie przez roślinność trawiastą, czyli gatunki wiechlinowate i turzycowate. W Polsce występuje około 160 gatunków traw (Nawara, 2006). Roślinność łąkowa, jeśli jest uprawiana na paszę, składa się głównie z wiechlinowatych i roślin motylkowych. Ponadto, na łąkach występują także gatunki zielne.

Wiechlinowate, czyli trawy, mają największe znaczenie ze względów gospodarczych i ekologicznych na terenie łąk. Trawy według kryterium morfologicznego

dzieli się na wysokie, średnio wysokie i niskie (Burs, Jankowska-Huflejt, Wróbel, Zastawny, 2004). Wysokie mają ponad 1 m wysokości. Są bardzo wartościowe ze względów rolniczych: mają dużą biomasę, a ich wysokość ułatwia zbiór. Należą do nich: wyczyniec łąkowy (*Alopecurus pratensis*), tymotka łąkowa (*Phleum pratense*), kupkówka pospolita (*Dactylis glomerata*), stokłosa bezostna (*Bromus inermis*) i rajgras wyniosły (*Arrhenatherum elatius*). Trawy średnio wysokie i niskie także zwiększają plon z łąk. Należy do nich np. wiechlina łąkowa (*Poa pratensis*). Na obszarze łąk występują także turzycowate zbliżone w budowie do traw, ale różniące się pod względem szczegółów morfologicznych. Na terenie

Polski występuje ich około 120 gatunków.

Rośliny, które zwiększają biomasa łąk i podnoszą zawartość białka w paszy, to gatunki motylkowe (Burs, Jankowska-Huflejt, Wróbel, Zastawny, 2004). Rośliny mają głęboki system korzeniowy i dlatego chronią glebę przed erozją. Duże znaczenie dla rolnictwa ma koniczyna biała (*Trifolium repens*), komonica zwyczajna (*Lotus corniculatus*), a nieco mniejsze lucerna siewna (*Medicago sativa*), koniczyna łąkowa (*Trifolium pratense*) i wyka ptasia (*Vicia cracca*).

Kolejną grupą występującą na terenie łąk są zioła i chwasty, czyli rośliny dwuliścienne. Ze względu na użytkowanie rolnicze zioła nigdy nie są wysiewane, ale ich niewielki udział (do 5%), jest pożądany, ponieważ mają właściwości lecznicze. Czerpią one wartościowe substancje podnoszące wartość pasz, z głębszych warstw gleby. Do roślin tego typu należy mniszek lekarski (*Taraxacum officinale*), szalwia łąkowa (*Salvia pratensis*), babka lancetowata (*Plantago lanceolata*), krwawnik pospolity (*Achillea millefolium*) i inne. Inne rośliny dwuliścienne, poza ziołami, obniżają wartość pasz i stanowią chwasty. Należą do nich: śmiełek darniowy (*Deschampsia caespitosa*), jaskry (*Ranunculaceae*), barszcz zwyczajny (*Heracleum sphondylium*), pokrzywa zwyczajna (*Urtica dioica*) i inne.

Łąki są dzielone w zależności od sposobu powstania na naturalne, półnaturalne i antropogeniczne (Stypiński, 2009). Łąki naturalne powstają tam, gdzie ze względu na warunki przyrodnicze nie mogą wykształcić się inne zbiorowiska, np. lasy. Do takich grup należą hale, murawy kserotermiczne i stepy. Użytki zielone półnaturalne powstały w wyniku działalności człowieka, czyli przez koszenie lub wypasanie zbiorowisk. Użytki zielone antropogeniczne zostały od początku założone przez człowieka i poddawane intensywnym zabiegom. Mają one prostą strukturę i najczęściej niewiele gatunków roślin. Badane w pracy łąki należą do kategorii półnaturalnych.

Badane w pracy łąki można określić jako ekstensywnie użytkowane. Na ich terenie występowały rośliny wiechlinowate, które stanowią główny składnik budujący roślinność, a także motylkowe, których zadaniem jest zwiększanie biomasy, a tym samym plonów i wzrost zawartości azotu w paszy (Burs, Jankowska-Huflejt, Wróbel, Zastawny, 2004). W przypadku zbiorowisk trawiastych, które są ekstensywnie użytkowane, charakterystyczne jest występowanie między innymi: tymotki łąkowej (*Phleum pratense*), wyki ptasiej (*Vicia cracca*), krwawnika pospolitego (*Achillea millefolium*), barszczu zwyczajnego (*Heracleum sphondylium*) i koniczyny białej (*Trifolium repens*) (Kucharski, 2009). Wymienione gatunki występowały na badanych obszarach.

Łąki można również podzielić ze względu na siedliska, na jakich są położone. Łąki łąkowe występują na siedliskach świeżych i umiarkowanie wilgotnych w pobliżu rzek; ich istnienie warunkują dostateczne opady (Bański, 2007; Stypiński, 2009). Jest to najbardziej zróżnicowany typ łąk; są one rozmieszczone na terenie całego kraju. Do tej kategorii należą wszystkie

badane poligony. Bardzo bogate gatunkowo łąki, czyli łąki zalewowe, są położone na tarasach zalewowych i mają zmienne warunki wodne. Na terenach z występującymi płytko wodami gruntowymi znajdują się łąki bagienne z utrudnionym odpływem wody.

Analizowane w pracy łąki pod względem składu gatunkowego, typu siedliska i intensywności użytkowania można określić jako półnaturalne świeże (Kucharski, 2009). Występują one zarówno na nizinach, jak i na obszarze pogórzy. Rozwinęły się na glebach brunatnych, madach i glebach organicznych. Poziom wody gruntowej jest zmienny, ale woda nie stagnuje na ich powierzchni.

W zależności od położenia łąki można podzielić na nizinne, nizinne pozadolinowe i górskie. Badane łąki można przypisać do dwóch grup: pogórskie (na Pogórzu Karpackim) oraz nizinne, czyli nizinne pozadolinowe i nizinne dolinne (na Równinie Środkowopolskiej). Do pierwszej grupy można przypisać zarówno łąki położone na wierzchołku pogórskiego garbu Wiatrówek, jak i w dolinie Bystrzanki. Przy naziemnych pomiarach terenowych nie stwierdza się istotnych różnic w rejestrowanych wartościach odbicia między łąkami górnymi a nizinnymi. Pewne rozbieżności mogłyby wystąpić w przypadku rejestracji danych z pułapu lotniczego lub satelitarnego, kiedy różne nachylenie stoku może modyfikować wartości współczynnika odbicia. Struktura poszczególnych rodzajów łąk występujących na terenach nizinnych i pogórskich była dość podobna, można jednak zauważyć, że na terenach nizinnych występowało nieco większe zróżnicowanie fitosocjologiczne.

Modele transferu promieniowania uogólniają symulowane środowisko. Im bardziej zróżnicowana jest jego struktura, tym trudniejsze jest symulowanie krzywych odbicia spektralnego. Dlatego występowanie wielu gatunków roślin, szczególnie o różnej budowie, oraz obecność innych gatunków poza trawami może obniżać skuteczność modelowania. Znaczna większość badanych łąk była właśnie porośnięta wieloma gatunkami roślin obudowie innej niż trawy: gatunkami motylkowymi, ziołami i roślinami kwitnącymi.

Część z łąk można także opisać jako podsiewane, czyli zawierające hodowlane rośliny motylkowe, głównie koniczynę łąkową. Przez dodanie roślin tego typu zwiększana jest biomasa, a tym samym plony z łąk. Ich udział na terenie łąk użytkowanych może sięgać nawet do 50% (Burs, Jankowska-Huflejt, Wróbel, Zastawny, 2004). Dodanie roślin motylkowych zmienia strukturę roślinności i wygląd łąk, co może wpływać na skuteczność modelowania odbicia promieniowania.

Koszenie jest jednym z głównych czynników wpływających na powstawanie zbiorowisk łąkowych (Kucharski, 2009). Rośliny w tym procesie tracą większość swojej powierzchni asymilacyjnej. Koszenie jest przeprowadzane cyklicznie, a rośliny przystosowują się do tego zabiegu. Koszenie, jego termin, częstość i wysokość pokosu mają wpływ na rośliny występujące na łące. Im częściej się kosi, tym większy jest udział roślin niskich. Zbyt wczesne koszenie może doprowadzić do gorszego rozwoju roślin późno zakwitających. Także zbyt niskie

koszenie usuwa zbyt dużą część roślin. Łąki ekstensywnie użytkowane koszone są dwa razy w roku, między 1 czerwca a 30 września.

Badane łąki podzielono na trzy kategorie w zależności od użytkowania i ilości biomasy: uprawiane o dużej biomacie, uprawiane o zredukowanej biomacie i nieuprawiane. Do łąk uprawianych zaliczono łąki, które są koszone co najmniej raz w sezonie wegetacyjnym. Do łąk nieuprawianych włączono łąki niekoszone w ciągu ostatniego roku. Łąki uprawiane były bardzo zróżnicowane pod względem struktury i roślinności. Do grupy tej zaliczono 43 poligony pomiarowe. Były to łąki dość intensywnie wykorzystywane (łąki koszone 3 razy w sezonie wegetacyjnym, z których plony są wysokie) i łąki koszone jedynie po to, aby nie zarosły innego typu roślinnością. Sytuacja ta wskazała na konieczność wyróżnienia wśród tych łąk grupy poligonów z łąkami uprawianymi o zredukowanej biomacie (skoszonymi) i uprawianymi o dużej biomacie (nieskoszonymi).

Łąki uprawiane o dużej biomacie zdefiniowano jako łąki, które są uprawiane, ale dawno nieskoszone i nie ma na nich śladów koszenia. Łąki uprawiane o zredukowanej biomacie to takie, gdzie roślinność dopiero odrasta po ostatnim koszeniu. Według zaleceń programu rolnośrodowiskowego wysokość koszenia na łąkach ekstensywnie użytkowanych powinna wynosić od 5 do 15 cm (Kucharski, 2009), w przypadku łąk intensywnie użytkowanych wysokość koszenia może wynosić około 5-7 cm (Burs, Jankowska-Huflejt, Wróbel, Zastawny, 2004). Mniejsza wysokość nie jest zalecana ze względu na wysychanie gleby, możliwość zanieczyszczenia pól glebą i wolniejszym odnawianiem się roślinności. W zależności od rodzaju łąki możliwe są dwa sposoby koszenia – ręczne lub mechaniczne (Radkowski, Kuboń, 2006). Koszenie mechaniczne może odbywać się z użyciem kosiarek; wówczas wysokość koszenia waha się od 3 do 12 cm, w zależności od rodzaju zastosowanego sprzętu. Po rozważeniu przytoczonych informacji przyjęto, że łąki uprawiane o zredukowanej biomacie mają wysokość pokrywy roślinnej mniejszą niż 20 cm.

Łącznie wykonano pomiary na 57 poligonach pomiarowych. Zbadano 30 łąk uprawianych o dużej biomacie, 13 poligonów uprawianych o zredukowanej biomacie i 14 nieuprawianych.

## Metodyka badań

### Methods

#### Modelowanie odbicia promieniowania od pojedynczych liści

##### *Reflectance modelling on leaf level*

W modelowaniu odbicia promieniowania od roślinności na poziomie pojedynczych liści użyto modelu PROSPECT. Model oblicza wartość odbicia i transmitancji w zakresie widma EM od 0,4 do 2,5  $\mu\text{m}$  (Jacquemoud, Baret, 1990; Jacquemoud, Ustin, Verdebout, Schmuck,

Anderoli, Hosgood, 1996; Feret, François, Asner, Gitelson, Martin, Bidet, Ustin, le Maire, Jacquemoud, 2008). Odbicie promieniowania od roślin zależy od właściwości chemicznych i fizycznych liści. Przy tworzeniu modelu brano pod uwagę parametry roślin takie, jak zawartość wody, pigmentów, głównie chlorofilu, białka, celulozy i jej pochodnych, ligniny, skrobi oraz masę liści (Jacquemoud, Ustin, Verdebout, Schmuck, Anderoli, Hosgood, 1996). Według założeń modelu, liść i jego właściwości są takie same z obu stron, jednakowe pod względem biochemicznym, a odbicie od liścia jest rozproszone w tym samym stopniu we wszystkich kierunkach. W modelu nie jest uwzględniana zawartość białek, celulozy i ligniny, co może powodować trudności w modelowaniu zawartości tych substancji. Innymi wadami modelu mogą być trudności w przeprowadzaniu inwersji, szczególnie w przypadku, gdy w roślinności występują suche liście.

W modelu zakłada się, że roślinność składa się z wielu prostych warstw liści o specyficznych właściwościach absorpcyjnych i refrakcyjnych oddzielonych od siebie warstwami powietrza (Jacquemoud, Baret, 1990). Liczba warstw materii w liściu jest oznaczona jako  $N$ , natomiast liczba warstw powietrza jest równa  $N-1$ .

Do prezentowanych w pracy badań wybrano model PROSPECT-5, czyli najnowszą wersję algorytmu. Parametry wejściowe do modelu PROSPECT-5 wraz z jednostkami zamieszczono w tabeli 1; wszystkie z nich mogą być zmierzone w terenie, z wyjątkiem parametru  $N$ .

Tab. 1. Dane wejściowe do modelu PROSPECT-5

Tab. 1. PROSPECT-5 input parameters

Symbol	Jednostka Units	Opis Description
$Cab$	$\mu\text{g}/\text{cm}^2$	Zawartość chlorofilu ( <i>Chlorophyll content</i> )
$Car$	$\mu\text{g}/\text{cm}^2$	Zawartość karotenoidów ( <i>Carotenoid content</i> )
$Cm$	$\text{g}/\text{cm}^2$	Zawartość materii suchej ( <i>Dry matter content</i> )
$Cw$	cm	Zawartość wody w liściach ( <i>Equivalent Water Thickness</i> )
$N$	-	Parametr strukturalny liści ( <i>Leaf structure parameter</i> )

Zawartość chlorofilu ( $Cab$ ) i karotenoidów ( $Car$ ) jest podana w  $\mu\text{g}$  na  $\text{cm}^2$  (Jacquemoud, Ustin, Verdebout, Schmuck, Anderoli, Hosgood, 1996; Feret, François, Asner, Gitelson, Martin, Bidet, Ustin, le Maire, Jacquemoud, 2008). Ilość barwnika jest mierzona w jednostkach masy ( $\mu\text{g}$ ), a następnie oblicza się stosunek tej ilości do powierzchni liści (w  $\text{cm}^2$ ), którą w tym przypadku używano ze wskaźnika powierzchni projekcyjnej liści LAI.

Zawartość materii suchej ( $Cm$ ) to stosunek wysuszonej masy liści (w gramach) do powierzchni projekcyjnej liści – LAI (Feret, François, Asner, Gitelson, Martin, Bidet, Ustin, le Maire, Jacquemoud, 2008). Wartość  $Cm$  jest wyrażona w gramach.

Ilość wody ( $Cw$ ) jest określana za pomocą *Equivalent Water Thickness* (Jacquemoud, Ustin, Verdebout,

Schmuck, Anderoli, Hosgood, 1996; Feret, François, Asner, Gitelson, Martin, Bidet, Ustin, le Maire, Jacquemoud, 2008). Zawartość wody oblicza się na podstawie różnicy wagi między biomasa świeżą a suchą. Ilość wody jest przeliczana na zawartość procentową, a następnie na zawartość wody w 1 cm<sup>3</sup>. Wartość jest dzielona przez powierzchnię projekcyjną liści podaną w cm<sup>2</sup>.

Ostatnią informacją wejściową jest parametr strukturalny *N*, który określa złożoność struktury wewnętrznej, komórkowej liści (Jacquemoud, Baret, 1990, Jacquemoud, Ustin, Verdebout, Schmuck, Anderoli, Hosgood, 1996; Feret, François, Asner, Gitelson, Martin, Bidet, Ustin, le Maire, Jacquemoud, 2008). Jest to liczba jednolitych warstw roślinności, jakie występują w roślinie. Parametr jest ściśle powiązany z ułożeniem komórek wewnątrz liścia. Parametr jest niezależny od długości fali. Najniższa wielkość parametru to 1, najwyższa w literaturze nie jest podawana (Jacquemoud, Baret, 1990).

Pomiary terenowe do modelu PROSPECT odbywały się na 22 poligonach znajdujących się na Pogórze Karpackim (7 poligonów) i na Mazowszu (15 poligonów). Wykonywano je w lipcu 2009 roku oraz w lipcu i sierpniu 2010 roku. Każdy z poligonów pomiarowych miał minimalną wielkość 100 m<sup>2</sup>. Na każdym z poligonów wybrano obszar reprezentatywny wielkości około 25 m<sup>2</sup>, gdzie dokonywano szczegółowych pomiarów.

W czasie badań terenowych na każdym z wyznaczonych poligonów zmierzono krzywe odbicia spektralnego, dane wejściowe do modelu PROSPECT, współrzędne geograficzne oraz wykonano dodatkowe pomiary.

Pomiary krzywych odbicia spektralnego wykonano przy użyciu spektrometru ASD FieldSpec 3 FR w świetle naturalnym. W czasie pomiarów na Pogórze Gorlickim błąd w kalibracji wystąpił w zakresie od 1,81 do 1,95 μm, natomiast na Mazowszu w trzech zakresach: 1,35-1,4, 1,81-1,945 i 2,45-2,5 μm. W celu ujednoczenia pomiarów i ułatwienia porównania krzywych odbicia spektralnego z każdego poligonu pobrano co najmniej 10 krzywych odbicia spektralnego, a następnie uśredniono je, aby dla każdego z poligonów powstała jedna krzywa odbicia spektralnego reprezentująca cały poligon.

Pomiary wejściowe do modelu PROSPECT obejmowały pomiary chlorofilu, masy suchej i zawartości wody. Zawartość chlorofilu mierzono za pomocą urządzenia CCM-200 *Chlorophyll Content Meter*. Na każdym poligonie wykonano po 10 pomiarów chlorofilu, które następnie uśredniono. Wykonano pomiary tak, aby liczba próbek każdego z gatunków była proporcjonalna do jej udziału w pokrywie roślinnej. Zawartość wody i masa sucha były określone przez zważenie biomasy świeżej i suchej. Wykonano także pomiary powierzchni projekcyjnej liści (*Leaf Area Index*) urządzeniem LAI-2000 *Plant Canopy Analyzer*.

Wyniki pomiarów z obu obszarów badawczych zostały przeliczone na dane wejściowe we właściwych jednostkach. Zawartość chlorofilu z wartości CCI została przeliczona na ilość w mikrogramach. Następnie obliczona zawartość chlorofilu z każdego poligonu pomiarowego

została podzielona przez powierzchnię liści w cm<sup>2</sup>, która była uzyskana z pomiarów *Leaf Area Index*. Zawartość karotenoidów przeliczono na podstawie zależności karotenoidów w stosunku do chlorofilu w zdrowych roślinach. Przeliczone je na podstawie wzoru:  $Car=Cab/5$ .

Zawartość masy suchej obliczono, dzieląc ilość masy suchej w gramach przez wartość LAI w cm<sup>2</sup>. Zawartość wody obliczono na podstawie różnicy wagi między biomasa świeżą a suchą. Ilość wody zważoną w pomiarach przeliczono na zawartość w procentach i zawartość wody w 1 cm<sup>3</sup>, a następnie na cm, dzieląc przez powierzchnię projekcyjną liści w cm<sup>2</sup>.

Ostatnią daną wejściową jest parametr strukturalny *N*. Nie było możliwe obliczenie wartości parametru. Na podstawie danych z literatury wartość wyznaczono jako 1, ze względu na przewagę traw w zbiorowiskach (Jacquemoud, Baret, 1990). W czasie modelowania wartość współczynnika odbicia okazała się jednak zbyt mała, na co wpływa głównie wartość parametru strukturalnego (Damarez, Gastellu-Etchegorry, 2000; Ceccato, Flasse, Tarantola, Jacquemoud, Grégoire, 2001). Wartości parametru *N* określono empirycznie w odniesieniu do każdego poligonu indywidualnie. Nie było możliwe założenie jednej wartości dotyczącej wszystkich poligonów, co jest prawdopodobnie związane z dość dużym zróżnicowaniem badanego środowiska. W tabeli 2 zamieszczono wykorzystane zakresy danych wejściowych.

Tab. 2. Zakres wartości parametrów wejściowych do modelu PROSPECT

Tab. 2. The value ranges of input PROSPECT parameters

Oznaczenie parametru <i>Parameter</i>	Jednostki <i>Units</i>	Zakres danych wejściowych <i>Input data range</i>
<i>Cab</i>	μg/cm <sup>2</sup>	29-382
<i>Car</i>	μg/cm <sup>2</sup>	6-76
<i>Cw</i>	cm	0,0004-0,0101
<i> Cm</i>	g/cm <sup>2</sup>	0,0048-0,0933
<i>N</i>	-	1-4,5

#### Modelowanie odbicia promieniowania od roślinności na poziomie pokrywy roślinnej

*Reflectance modelling on canopy level*

Model SAIL (*Scattering by Arbitrarily Inclined Leaves*) służy do modelowania współczynnika odbicia spektralnego na poziomie pokrywy roślinności (Verhoef, 1984, 1985). Opisuje różne typy interakcji w promieniowaniu dochodzącym, przechodzącym, rozproszonym i odbitym między pokrywą roślinną a źródłem promieniowania. Model uwzględnia odbicie od roślin i gleby. Opisuje pokrywę roślinności jako warstwę składającą się z pojedynczych elementów, wewnątrz których wszystkie komponenty są losowo i równomiernie zmieszane.

Model SAIL definiuje cztery strumienie energetyczne:

promieniowanie słoneczne padające na powierzchnię poziomą roślinności, promieniowanie rozproszone dochodzące i odbite od pokrywy roślinności oraz promieniowanie dochodzące do sensora pod odpowiednim kątem, zgodnie z teorią Suitsa (1972, za Verhoef, 1984).

W modelu zakłada się, że: (1) roślinność jest jednorodna w pionie i w poziomie; (2) transmitancja przez liście jest rozproszona równomiernie we wszystkich kierunkach; (3) odbicie od liści i gleby jest rozproszone (Verhoef, 1984, Jacquemoud, Baret, Hanocq, 1992; Gastellu-Etchegorry, Zagolski, Romier, 1996; Verhoef, Bach, 2007; Verhoef, Jia, Xiao, Su, 2007); (4) azymutalne rozmieszczenie liści jest losowe; (5) wszystkie liście w pokrywie roślinności są małe i płaskie (Verhoef, 1984). Model nie uwzględnia odbicia od innych elementów roślinności, takich jak gałęzie czy kwiaty i dlatego powinien być używany do dość jednorodnych powierzchni. Również w przypadku, gdy występują znaczne prześwity tła, czyli gleby, modelowanie może nie przebiegać prawidłowo (Gastellu-Etchegorry, Zagolski, Romier, 1996).

Ze względu na trudności w inwersji samego modelu SAIL najczęściej łączy się go z modelem na poziome pojedynczych liści – PROSPECT. Powstały model PROSAIL jest od lat stosowany w badaniach roślinności. Przegląd badań wykonanych za jego pomocą został zaprezentowany w artykule twórców modelu (Jacquemoud, Verhoef, Baret, Bacour, Zarco-Tejada, Asner, François Ustin, 2009). PROSAIL umożliwia symulację krzywych odbicia spektralnego do analiz skuteczności modelowania, testowania wskaźników roślinności itp. Po

przeprowadzaniu inwersji był on używany do badania parametrów biofizycznych, zwłaszcza zawartości chlorofilu, wody, masy suchej i LAI. PROSAIL jest częściej stosowany niż inne modele, ze względu na dobre rezultaty i dokładność oraz dobrą dostępność. Ponadto, mimo dużej liczby danych wejściowych, model jest stosunkowo nieskomplikowany.

W przeglądzie literatury wspomniano o kilku wersjach modelu SAIL różniących się danymi wejściowymi, wprowadzonymi modyfikacjami i ulepszeniami, a także rodzajem roślinności, do której mogą być zastosowane (Verhoef, Bach, 2007). Do niniejszych badań wybrano wersję 4SAIL (Verhoef, Xiao, Jia, Su, 2007). Jest to modyfikacja poprzedniego modelu – SAILH. 4SAIL jest modelem hybrydowym, uwzględnia efekt *hot spot*, w obliczeniach jest dokładniejszy i szybszy niż poprzednie wersje modelu SAIL (Verhoef, Bach, 2007). Na ogół stosowany jest raczej do jednolitych baldachimów roślinności, takich jak zboża. Parametry te wraz z jednostkami zostały zmieszane w tabeli 3.

Zawartość brązowych pigmentów (*Cbrown*) w roślinach określa, jaka jest zawartość pigmentów odpowiedzialnych za starzenie się rośliny, czyli dla uproszczenia – pigmentów innych niż chlorofil (Verhoef, Bach, 2003; Houborg, Soegaard, Boegh, 2007; Duveiller, Weiss, Baret, Defourny, 2011). Zmienna opisuje absorpcję światła przez te pigmenty. Im mniejsza jest zawartość zielonego pigmentu, tym większy jest udział innych barwników, takich jak karotenoidy. Jego wielkość waha się od 0, gdy nie występuje absorpcja promieniowania

Tab. 3. Parametry wejściowe do modelu PROSAIL

Tab. 3. *Input parametrs to PROSAIL model*

Model	Oznaczenie zmiennej <i>Abbreviation</i>	Nazwa zmiennej <i>Input variable</i>	Jednostki <i>Units</i>
PROSPECT-5	<i>Cab</i>	Zawartość chlorofilu ( <i>Chlorophyll content</i> )	$\mu\text{g}/\text{cm}^2$
	<i>Car</i>	Zawartość karotenoidów ( <i>Carotenoid content</i> )	$\mu\text{g}/\text{cm}^2$
	<i>Cbrown</i>	Udział brązowych pigmentów (tanin) w roślinie ( <i>Brown pigment content / fraction brown leaf area</i> )	-
	<i>Cw</i>	Ilość wody ( <i>Equivalent Water Thickness</i> )	cm
	<i>Cm</i>	Zawartość masy suchej ( <i>Dry matter content</i> )	$\text{g}/\text{cm}^2$
	<i>N</i>	Parametr strukturalny liści ( <i>Leaf structure parameter / structure coefficient</i> )	-
4SAIL	<i>LAI</i>	Powierzchnia projekcyjna liści ( <i>Leaf Area Index</i> )	$\text{m}^2/\text{m}^2$
	<i>angl</i>	Średni kąt nachylenia liści ( <i>Average leaf angle / mean leaf inclination angle</i> )	Stopnie/degrees
	<i>posil</i>	Parametr określający jasność gleby ( <i>Soil factor / soil brightness parameter</i> )	-
	<i>skyl</i>	Parametr określający stosunek promieniowania rozproszonego do bezpośredniego ( <i>Ratio of diffuse to total incident radiation</i> )	%
	<i>hspot</i>	Parametry określające efekt nadmiernego odbicia ( <i>Hot spot size parameter</i> )	m/m
	<i>ihot</i>		-
	<i>tts</i>	Kąt zenitalny Słońca ( <i>Solar zenith angle</i> )	Stopnie/degrees
	<i>tto</i>	Kąt zenitalny urządzenia pomiarowego ( <i>Observer zenith angle</i> )	Stopnie/degrees
<i>psi</i>	Kąt azymutalny urządzenia pomiarowego ( <i>Azimuth / Relative azimuth angle</i> )	Stopnie/degrees	

przez pigmenty inne niż chlorofil, do maksymalnie 6 w przypadku roślinności wysuszonej (Houborg, Anderson, Daughtry, 2009).

Danymi z modelu SAIL są wartości parametrów opisujących morfologię roślinności, w tym powierzchnia projekcyjna liści (*Leaf Area Index*), która określa, jaka jest powierzchnia liści na daną jednostkę terenu.

Nachylenie liści opisywane jest w modelu funkcją *Leaf Inclination Distribution Function* (Jacquemoud, Verhoef, Baret, Bacour, Zarco-Tejada, Asner, François Ustin, 2009, Houborg, Soegaard, Boegh, 2007). W części modeli, w tym w wersji 4SAIL, średni kąt nachylenia liści (*angl*) jest podawany w stopniach od 0 do 90°. Wartość 0° oznacza, że wszystkie liście są ułożone horyzontalnie, czyli równoległe do powierzchni terenu, natomiast wartość bliska 90° występuje w przypadku roślin o liściach ustawionych pionowo.

Kolejne parametry dotyczą tła, czyli odbicia promieniowania od gleby. Dane są ograniczone do jednego parametru (*psoil*), opisywanego jak parametr jasności gleby (le Maire, François, Soudani, Berveiller, Pontalier, Bréda, Genet, Davi, Dufrêne, 2008). Parametr najczęściej jest wyznaczany jako stały. Autorzy modelu określili, że w przypadku gleby wilgotnej wartość wynosi 0, a suchej 1 (Verhoef, 1984, 1985; Verhoef, Bach, 2007).

Następny parametr (*skyl*) określa stosunek intensywności promieniowania rozproszonego do promieniowania bezpośredniego, mierzonego na jednostkę powierzchni (Yao, Liu, Liu, Li, 2008, Jacquemoud, Verhoef, Baret, Bacour, Zarco-Tejada, Asner, François Ustin, 2009). Jego wartość zależy od długości fali, a także od kąta zenitalnego Słońca, ma on jednak minimalne znaczenie dla modelowania i na ogół ustalany jest jako parametr stały (Jacquemoud, 1993; Darvishzadeh, Skidmore, Schlerf, Atzberger, 2008; Vohland, Mader, Dorigo, 2010; Darvishzadeh, Atzberger, Skidmore, Schlerf, 2011). W wersji modelu 4SAIL wartość tego parametru jest podawana w procentach. Jako wzorcową podano wartość 70% (<http://teledetection.ipgp.jussieu.fr/prosail/>).

Kolejne parametry służą do określania wielkości efektu *hot spot*, czyli nadmiernego odbicia – *hspot* i *ihot*. Pierwszy z nich to iloraz rozmiaru liści do wysokości pokrywy roślinnej; obie wartości są podawane w metrach (Kuusk, 1991; Verhoef, 1985; Darvishzadeh, Skidmore, Schlerf, Atzberger, 2008). Rozmiar liści jest określany za pomocą projekcji długości liścia rzutowanej na płaszczyznę poziomą – długości cienia liścia w momencie, gdy promień jest prostopadły do płaszczyzny pokrywy roślinnej (Verhoef, Bach, 200; Jacquemoud, Bacour, Poilvé, Frangi, 2000). W przypadku roślinności łąkowej używano wartości od 0,05 do 0,1 (Darvishzadeh, Atzberger, Skidmore, Schlerf, 2011). Drugi parametr (*ihot*) ustalany jest jako stała wartość równa 1. Przyjęta wartość odnosi się do standardowej pokrywy roślinnej i jest założona przez twórców tej wersji modelu (<http://teledetection.ipgp.jussieu.fr/prosail/>; Verhoef, Bach, 2007).

Ostatnie parametry dotyczą geometrii odbicia: kąta zenitalnego Słońca (*tts*) oraz kątów widzenia sensora

– zenitalnego (*tto*) i azymutalnego (*psi*). Kąt zenitalny Słońca jest wyznaczany na podstawie czasu pomiarów – daty i godziny. Kąty widzenia sensora zenitalny i azymutalny określają jego położenie w stosunku do powierzchni roślinnej.

Pomiary terenowe do modelu PROSAIL odbywały się wyłącznie na terenie Mazowsza na obszarze 50 poligonów. Każdy z 50 poligonów miał minimalne rozmiary 5 na 5 m. Pomiary przeprowadzano na wybranej powierzchni 25 m<sup>2</sup> reprezentatywnej dla całego poligonu. Pobrano dane stanowiące parametry wejściowe do modelu PROSAIL. Na każdym z poligonów wykonywano te same pomiary terenowe, które stanowiły podstawę do obliczania parametrów wejściowych do modelu, referencyjne krzywe odbicia spektralnego oraz pomiary dodatkowe.

Tak samo jak w przypadku pomiarów do modelu PROSPECT, zmierzono krzywe odbicia spektralnego roślin przy użyciu spektrometru FieldSpec 3 FR w świetle naturalnym. Wykonano także takie same pomiary jak w przypadku pomiarów do modelu PROSPECT: zawartość chlorofilu przy użyciu CCN-200 *Chlorophyll Content Meter*, biomasa świeżą z 0,25 m<sup>2</sup> i pomiary *Leaf Area Index* za pomocą urządzenia *LAI Plant Canopy Analyzer*.

Dwa parametry oceniono wizualnie: średni kąt nachylenia liści i udział suchych części roślin, który świadczy o zawartości brązowych pigmentów. Średni kąt nachylenia liści był oceniany w zależności od rodzaju roślinności i udziału roślin wiechlinowatych. Im większy był udział roślin trawistych, tym większy był kąt nachylenia liści – zbliżał się do 90°. Udział części suchych wizualnie oceniono w procentach na podstawie próbek, która została pobrana do określania biomasy świeżej.

Określono średni rozmiar liści przez zmierzenie długości co najmniej dziesięciu liści. Zmierzono także średnią wysokość pokrywy roślinnej. Przy zróżnicowanej wysokości, co miało miejsce w przypadku wszystkich łąk nieuprawianych i części uprawianych o zróżnicowanej budowie, uśredniano wysokości z co najmniej pięciu pomiarów. Wśród pomiarów dodatkowych rejestrowano dane odnośnie do lokalizacji poligonu za pomocą urządzenia GPS. W każdym punkcie zapisano datę i godzinę pomiaru. Określono także występujące na terenie gatunki roślin i typ zbiorowiska.

Wszystkie dane zostały zgromadzone w bazie danych. Następnie obliczono dane wejściowe do modelu PROSAIL. Część parametrów mogła być od razu wprowadzona do modelu, część wymagała zmian w jednostkach, inne były obliczane, a cztery parametry przyjęto jako stałe (wartości ustalono na podstawie literatury). Poniżej opisana jest metoda pozyskiwania kolejnych parametrów wejściowych.

Tak samo jak w przypadku pomiarów do modelu PROSPECT, obliczono zawartość chlorofilu (*Cab*) i karotenoidów (*Car*) w µg na cm<sup>2</sup>, ilość wody w roślinie w cm (*Cw*) i masy suchej w g/cm<sup>2</sup> (*Cm*). Podobnie oszacowano początkowe wartości parametru strukturalnego *N* (Darvishzadeh, Skidmore, Schlerf, Atzberger, 2008; Clevers, Kooistra, Schaepman, 2010).

Powierzchnia projekcyjna liści była określona przez

*Leaf Area Index* podawany w  $m^2/m^2$ . Parametr nie wymagał żadnych zmian, ponieważ w takiej postaci dane były pobierane w terenie przy użyciu LAI-2000 *Plant Canopy Analyzer*. Średni kąt nachylenia liści (*angl*) także nie wymagał dodatkowych przekształceń.

Następnie oszacowano zakres parametru określającego zawartość brązowych pigmentów w liściach (*Cbrown*). Wizualnie oceniono udział żółtych roślin od 0 do 70%, a średnio na 17%. Zakres podawany w literaturze obejmuje wartości od 0 dla roślinności zielonej pozbawionej pigmentów brązowych, do 3 ewentualnie 6 dla roślin zupełnie wysuszonych (Houborg, Anderson, Daughtry, 2009; Verger, Baret, Camacho, 2011). Przyjęto, że wyłącznej zawartości części suchych (100%) będzie odpowiadała wartość parametru *Cbrown* 3, a całkowitemu ich brakowi (0%) wartość 0. Następnie zawartość części suchych wyrażona w procentach została proporcjonalnie przeliczona na wartości parametru w zakresie od 0 do 3.

Parametr określający jasność gleby (*psoil*) został ustalony jako stała wartość 1 na podstawie danych z literatury (Combal, Baret, Weiss, Trubuil, Macé, Pragnère, Myneni, Knyazikhin, Wang, 2002; Darvishzadeh, Skidmore, Schlerf, Atzberger, 2008). Wykorzystano średnią wartość z zakresu wymienionego w publikacjach od 0,5 do 1,5.

Kolejnym stałym elementem modelu był parametr określający stosunek promieniowania rozproszonego do bezpośredniego (*skyl*), którego wartość ustalono na 70%. W tym przypadku także wzorowano się na standardowej wartości podanej przez twórców modelu (<http://teledetection.ipgp.jussieu.fr/prosail/>).

Kolejne dwa parametry opisują efekt *hot spot*. Pierwszy z nich (*hspot*) jest określony przez stosunek rozmiaru

liści do wysokości pokrywy roślinnej (Kuusk, 1991; Verhoef, 1985; Verhoef, Bach, 2007; Darvishzadeh, Skidmore, Schlerf, Atzberger, 2008). Parametr był obliczany z danych zmierzonych w terenie: długości liści, średniego kąta nachylenia liści i wysokości pokrywy roślinnej. W przypadku drugiego parametru (*ihot*) ustalono wartość stałą – równą 1. Przyjęta wartość jest określona dla standardowej pokrywy roślinności, założona przez twórców tej wersji modelu (<http://teledetection.ipgp.jussieu.fr/prosail/>).

Ostatnim etapem było określenie kątów opisujących geometrię odbicia. Na podstawie godziny, daty i miejsca pomiaru obliczono kąt zenitalny Słońca (*tts*) podczas każdego pomiaru oddzielnie. Wykorzystano do tego kalkulator umieszczony na stronie: <http://www.usno.navy.mil/USNO/astronomical-applications/data-services/alt-az-world>. Parametr ten przybierał wartości od  $32^\circ$  do  $52^\circ$ .

Jako stałe określono kąty zenitalny (*tto*) i azymutalny (*psi*) urządzenia pomiarowego. Spektrometr zawsze był ustawiany w ten sam sposób – prostopadle do pokrywy roślinnej bezpośrednio nad miejscem pomiaru; oba kąty były równe  $0^\circ$ .

Parametr strukturalny *N* wymagał dopasowania do poszczególnych zbiorowisk roślinnych. Tak samo jak w przypadku modelu PROSPECT, określenie jednej wartości parametru dla każdego z poligonów okazało się niemożliwe ze względu na niejednorodność środowiska.

Krzywe odbicia spektralnego zgromadzono w bazie danych. Dla każdego z poligonów uśredniono krzywe i usunięto te same zakresy co w przypadku modelowania z użyciem modelu PROSPECT, tzn. 1,35-1,4  $\mu m$ , 1,81-1,945  $\mu m$  i 2,45-2,5  $\mu m$ .

Tab. 4. Zakres wartości parametrów wejściowych do modelu PROSAIL

Tab. 4. The value ranges of input PROSAIL parameters, zakres – range of values, stała – constant value

Model	Oznaczenie zmiennej Parameter	Wartości Values	Jednostki Units	Wartości parametrów Values of parametrs
PROSPECT-5	<i>Cab</i>	zakres	$\mu g/cm^2$	28,8-278,8
	<i>Car</i>	zakres	$\mu g/cm^2$	5,8-55,7
	<i>Cbrown</i>	zakres	-	0-2,1
	<i>Cw</i>	zakres	cm	0,0002-0,0103
	<i>Cm</i>	zakres	$g/cm^2$	0,006-0,0933
	<i>N</i>	zakres	-	1-50
4SAIL	<i>LAI</i>	zakres	$m^2/m^2$	0,7-7,4
	<i>angl</i>	zakres	stopnie	45-90
	<i>posil</i>	stała	-	1
	<i>skyl</i>	stała	%	70
	<i>hspot</i>	zakres	m/m	0,015-0,956
	<i>ihot</i>	stała	-	1
	<i>tts</i>	zakres	stopnie	32-53
	<i>tto</i>	stała	stopnie	0
	<i>psi</i>	stała	stopnie	0

Po obliczeniu parametrów wejściowych kolejnym etapem było dokończenie fragmentu kodu programu PRO-SAIL, aby możliwe było wczytanie krzywych i uzyskanie krzywych odbicia spektralnego zapisywanych do pliku. Nie wpłynęło to na modyfikowanie działania samego programu. Następnie wprowadzono dane wejściowe do modelu z każdego poligonu indywidualnie. Zakresy danych wejściowych umieszczono w tabeli 4.

### Weryfikacja i opracowanie wyników badań

*Verification and elaborated of the research results*

Ostatnim etapem badań była weryfikacja uzyskanych wartości odbicia z dwóch modeli przez porównanie z wartościami zmierzonymi w terenie. Przeanalizowano błędy w modelowaniu poszczególnych krzywych odbicia spektralnego dotyczących poligonów oraz wartości błędu uśrednione w zależności od kategorii łąk i zawartości wybranych parametrów biofizycznych.

Aby zweryfikować skuteczność modelowania obliczono pierwiastek błędu średniokwadratowego (*Root Mean Square Error* – RMSE) dla każdej modelowanej krzywej. W ten sam sposób krzywe odbicia spektralnego były weryfikowane w innych opracowaniach (Nouvellon, Moran, Seen, Bryant, Rambal, Ni, Bégué, Chehbouni, Emmerich, Heilman, Qi, 2001; Darvishzadeh, Atzberger, Skidmore, Schlerf, 2011; Yerba, Chuvieco, Riaño, 2008, Zhang, Zhao, 2009). Wartość RMSE obliczono ze wzoru:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (R_{terenowe} - R_{modelowane})^2}{n}}$$

gdzie:

$R_{terenowe}$  – wielkość współczynnika odbicia fali o długości  $\lambda$  zmierzona w terenie;

$R_{modelowane}$  – wielkość współczynnika odbicia fali o długości  $\lambda$  uzyskana z modelu,

$n$  – liczba długości fali, dla których liczone wielkość błędu.

Wielkość błędu była policzona w odniesieniu do wszystkich poligonów w zakresie od 0,4 do 2,5  $\mu\text{m}$ . Przy obliczaniu RMSE nie brano pod uwagę usuniętych zakresów. Obliczono średnią także w zależności od długości fali: w dwóch zakresach w świetle widzialnym – 0,4-0,6  $\mu\text{m}$  i 0,4-0,8  $\mu\text{m}$  oraz w zakresach w podczerwieni bliskiej (0,8-1,5  $\mu\text{m}$ ) i środkowej (1,5-2,5  $\mu\text{m}$ ). Zakresy te są związane z parametrami, które mają największy wpływ na wielkość odbicia. W przypadku pierwszego zakresu na modelowanie mają wpływ wszystkie parametry modelu, ale dominuje zawartość barwników (karotenoidów i chlorofilu). Na zakres 0,4-0,8  $\mu\text{m}$  największy wpływ ma chlorofil. W zakresie od 0,8 do 1,5  $\mu\text{m}$  dominujący wpływ ma zawartość masy suchej i LAI. W ostatnim zakresie dominuje zawartość wody. Następnie wartości RMSE zostały uśrednione dla wszystkich poligonów w wynikach dla obu modeli.

Kolejnym etapem było określenie wielkości średniego błędu modelowania w zależności od rodzaju łąk. Wszystkie poligony podzielono na trzy kategorie: uprawiane o zredukowanej biomase (skoszone), uprawiane o dużej biomase i nieuprawiane. Policzone średnie wartości błędu RMSE w całym zakresie 0,4-2,5  $\mu\text{m}$  i w 4 fragmentach spektrum w przypadku wszystkich badanych rodzajów łąk. Określono istotność statystyczną różnic między grupami używając rangowego nieparametrycznego testu Kruskala-Wallisa dla trzech prób niezależnych ze względu na to, że rozkłady wskaźników nie miały charakteru normalnego.

Obliczono średnią wielkość błędu RMSE w zależności od zmiennych biofizycznych roślinności: ilości biomasy świeżej, wielkości parametru LAI i procentowej zawartości wody. Wyróżniono trzy kategorie poligonów pomiarowych, z odpowiednio zdefiniowanym przedziałem wartości każdego z tych parametrów (tab. 5.).

Tab. 5. Kategorie poligonów ze względu na wartość badanych parametrów

*Tab. 5. The different type of polygons regarding to the bio-physical parameters*

Parametr <i>Parameter</i>	Kategoria I <i>First type</i>	Kategoria II <i>Second type</i>	Kategoria III <i>Third type</i>
Biomasa świeża ( <i>Fresh biomass</i> ) ( $\text{kg}/\text{m}^2$ )	<0,75	0,76 - 1,5	> 1,5
Powierzchni liści ( <i>Leaf Area Index</i> ) ( $\text{m}^2/\text{m}^2$ )	<2	2,01 - 4	>4
Zawartości wody ( <i>Water content</i> ) (%)	<70	70,1 - 80	>80

W każdym podziale brano pod uwagę rozpiętość zmiennej i liczebność poligonów w każdej z kategorii. Następnie obliczono średnią wielkość błędu RMSE w całym modelowanym zakresie widma EM w wymienionych czterech zakresach tego widma (0,4-0,6  $\mu\text{m}$ , 0,4-0,8  $\mu\text{m}$ , 0,8-1,5  $\mu\text{m}$ , 1,5-2,5  $\mu\text{m}$ ) w przypadku każdego parametru i kategorii poligonu. Także w tym przypadku określono istotność statystyczną różnic między kategoriami za pomocą rangowego testu nieparametrycznego Kruskala-Wallisa dla trzech prób niezależnych.

### Skuteczność modelowania charakterystyk spektralnych

*Efficiency modelling of the spectral reflectance*

Omówienie wyników uzyskanych w trakcie badań podzielono na dwie części. Pierwsza część dotyczy wyników badań przeprowadzonych z użyciem modelu PROSPECT, w drugiej zaś przedstawiono wyniki uzyskane za pomocą modelu PROSAIL. Obie części łączą wspólnota narzędzi analitycznych zastosowanych do obu modeli.



Na początku przedstawiono uśrednione wartości pierwiastka błędu średniokwadratowego (określanego w tekście także jako „błąd”) obliczone w całym badanym zakresie widma od 0,4 do 2,5  $\mu\text{m}$  i czterech jego fragmentach: 0,4-0,6; 0,4-0,8; 0,8-1,5 i 1,5-2,5  $\mu\text{m}$ . Następnie opisano wartości pierwiastka błędu średniokwadratowego w poszczególnych zakresach widma i scharakteryzowano poligony o największych i najmniejszych wartościach błędów z punktu widzenia uzyskanych dla nich krzywych odbicia spektralnego na podstawie zastosowanych modeli. W dalszym toku postępowania określono średnie wartości pierwiastka błędu średniokwadratowego w zależności od podziału poligonów na kategorie łąk i w zależności od wartości parametrów biofizycznych.

#### Symulacja charakterystyk spektralnych na poziomie pojedynczych liści z użyciem modelu PROSPECT

*Simulation of the spectral reflectances on the single leaves level with PROSPECT model*


**Skuteczność modelu PROSPECT w modelowaniu charakterystyk spektralnych łąk badanych poligonów w wybranych zakresach widma.** Przedstawione badania z użyciem modelu PROSPECT

przeprowadzono na 22 poligonach. Najpierw przeanalizowano wartości RMSE w zależności od długości fali. Badaniami objęto zarówno cały badany zakres widma elektromagnetycznego (0,4-2,5  $\mu\text{m}$ ), jak i jego części: 0,4-0,6; 0,4-0,8; 0,8-1,5 i 1,5-2,5  $\mu\text{m}$ . Średni błąd w zakresie 0,4-2,5  $\mu\text{m}$  wyniósł 0,099. Największy błąd był w zakresie środkowej podczerwieni – 0,1151, a nieco mniejszy w bliskiej podczerwieni – 0,0964. Zdecydowanie mniejsze błędy były w zakresach: 0,4-0,8  $\mu\text{m}$  – 0,0398 i 0,4-0,6  $\mu\text{m}$  – 0,0287.

Następnie zbadano wartości błędów krzywych reprezentujących poszczególne poligony badawcze. Zbadano wartości pierwiastka błędu średniokwadratowego krzywych i na podstawie danych terenowych (ryc. 3).

Zakres 0,4-2,5  $\mu\text{m}$ . Największa rozbieżność w przebiegu krzywych spektralnych wyrażana pierwiastkiem błędu średniokwadratowego w całym zakresie 0,4-2,5  $\mu\text{m}$  wystąpiła w przypadku poligonu P2.2; wartość błędu wyniosła tam 0,1877. Najmniejsza wartość tego błędu (0,032) była w przypadku poligonu R12.

Najlepiej modelowaną krzywą odbicia spektralnego w całym zakresie widma (0,4 do 2,5  $\mu\text{m}$ ) był poligon R12 (ryc. 4.); znajdował się on na Równinie Mszczonowskiej w okolicy Radziejowic. Na występujących tu jednorodnych łąkach rosły rośliny należące do rodziny wiechlinowatych: kupkówka pospolita (*Dactylis glomerata*),



Ryc. 3. Wartości pierwiastka błędu średniokwadratowego między krzywymi odbicia spektralnego modelowanymi z użyciem PROSPECT i uzyskanymi z pomiarów terenowych. Zakresy spektrum: 1 – 0,4-2,5  $\mu\text{m}$ ; 2 – 0,4-0,6  $\mu\text{m}$ ; 3 – 0,4-0,8  $\mu\text{m}$ ; 4 – 0,8-1,5  $\mu\text{m}$ ; 5 – 1,5-2,5  $\mu\text{m}$


*Fig. 3. The values of Root Mean Square Error calculated using data obtained in spectral reflectance field measurements and spectral reflectance modelled using PROSPECT. Wavelength: 1 – 0,4-2,5  $\mu\text{m}$ ; 2 – 0,4-0,6  $\mu\text{m}$ ; 3 – 0,4-0,8  $\mu\text{m}$ ; 4 – 0,8-1,5  $\mu\text{m}$ ; 5 – 1,5-2,5  $\mu\text{m}$*

tymotka łąkowa (*Phleum pratense*) i mietlica pospolita (*Agrostis capillaris*). Była to łąka nieuprawiana (niepodsiewana i niekoszona). Błąd w przebiegu krzywej spektralnej w obrębie całego modelowanego zakresu był niewielki i wyniósł 0,032. Podobnie niewielki błąd wystąpił w zakresie środkowej podczerwieni. Mimo najmniejszego błęd, krzywa znacząco różniła się od krzywej wyznaczonej na podstawie pomiarów terenowych, co jest szczególnie widoczne w zakresie promieniowania widzialnego, w którym nie zaznaczyło się zwiększenie odbicia promieniowania.

Największy błąd w modelowaniu krzywych odbicia spektralnego w zakresie 0,4-2,5  $\mu\text{m}$  wystąpił w przypadku poligonu P2.2; wartość pierwiastka błędu średniokwadratowego wyniosła 0,1877 (ryc. 5.). Łąka ta była położona w dolinie Bystrzanki na terenie Pogórza Gorlickiego. Porośnięta była wiechliną zwyczajną (*Poa trivialis*) i mniszkiem lekarskim (*Taraxacum officinale*),


dlatego została ona określona jako jednorodna. Łąka była uprawiana, skoszona, czyli o zredukowanej ilości biomasy. Modelowana krzywa odbicia spektralnego w zakresie widzialnym była dobrze dopasowana do krzywej „terenowej”. Wartość pierwiastka błędu średniokwadratowego wyniosła tu 0,0266. W zakresie podczerwonym krzywe bardzo znacząco różniły się między sobą. Na wielkość błędu wpłynęła głównie niska wartość parametru określającego zawartość wody w liściach ( $C_w$ ).

Zakres 0,4-0,6  $\mu\text{m}$ . W zakresie tym wszystkie pięć parametrów wejściowych do modelu miały wpływ na wartość odbicia promieniowania: parametr strukturalny, zawartość wody, materia sucha, chlorofil i karotenoidy. Modelowana krzywa odbicia spektralnego była w tym zakresie dobrze dopasowana do krzywej „terenowej”. Niedopasowanie krzywej modelowanej wyrażane wartościami pierwiastka błędu średniokwadratowego było w tym zakresie widma najmniejsze i wykazywało nie-



Ryc. 4. Krzywe odbicia spektralnego według danych terenowych (1) i modelowanych z użyciem PROSECT (2) – poligon R12

Fig. 4. The spectral reflectance from field measurements (1) and modeled using PROSECT (2) – R12 research area



Ryc. 5. Krzywe odbicia spektralnego według danych terenowych (1) i modelowanych z użyciem PROSECT (2) – poligon P2.2

Fig. 5. The spectral reflectance from field measurements (1) and modeled using PROSECT (2) – P2.2 research area

wielkie różnice między poligonami. Wartości te mieściły się w zakresie od 0,0133 w przypadku łąki na poligonie D1 do 0,0967 na poligonie T6.

Najmniejszą wartość pierwiastka błędu (0,0133) w zakresie 0,4-0,6  $\mu\text{m}$  stwierdzono na poligonie D1, położonym w Dolinie Środkowej Wisły w powiecie otwockim (ryc. 6.). Była to łąka podsiewana, niedawno koszona, czyli o mniejszej biomasy. Łąkę można było określić jako jednorodną, ponieważ była porośnięta dwoma gatunkami traw: mietlicą pospolitą (*Agrostis capillaris*) i kupkówką pospolitą (*Dactylis glomerata*) oraz w niewielkim stopniu koniczyną łąkową (*Trifolium pratense*). W badanym zakresie widma rozbieżność krzywych odbicia spektralnego była nieznaczna, przy nieco większych wartościach modelowanych.


Największe rozbieżności w przebiegu krzywych spektralnych w zakresie widma 0,4-0,6  $\mu\text{m}$  wystąpiły na poligonie T6, znajdującym się na grzbiecie Tabo-

rówki na Pogórzu Gorlickim (ryc. 7.). Wartość pierwiastka błędu średniokwadratowego wyniosła 0,0967. Łąka ta nie była koszona, a była podsiewana roślinami motylkowymi, co oznacza, że charakteryzowała się dużą biomasa. Łąka była porośnięta rajgrasem wyniosłym (*Arrhenatherum elatius*), koniczyną łąkową (*Trifolium pratense*) i mniszkiem lekarskim (*Taraxacum officinale*). Była określona jako niejednorodna ze względu na udział roślin innych niż wiechlinowate. Modelowana krzywa spektralna w zakresie widzialnym miała mniejsze wartości niż krzywa sporządzona na podstawie pomiarów terenowych. Jest to szczególnie widoczne w przypadku zakresu światła zielonego, gdzie krzywa modelowana miała podobne wartości jak w zakresie niebieskim i czerwonym.

Zakres 0,4-0,8  $\mu\text{m}$ . Kolejny zakres widma obejmuje całość promieniowania widzialnego i niewielki fragment bliskiej podczerwieni – 0,4-0,8  $\mu\text{m}$ . W zakresie


Ryc. 6. Krzywe odbicia spektralnego według danych terenowych (1) i modelowanych z użyciem PROSPECT (2) – poligon D1

Fig. 6. The spectral reflectance from field measurements (1) and modeled using PROSPECT (2) – D1 research area



Ryc. 7. Krzywe odbicia spektralnego według danych terenowych (1) i modelowanych z użyciem PROSPECT (2) – poligon T6

Fig. 7. The spectral reflectance from field measurements (1) and modeled using PROSPECT (2) – T6 research area



od 0,4 do 0,6  $\mu\text{m}$  na odbicie ma wpływ pięć parametrów wejściowych, dominujący jest jednak wpływ chlorofilu i karotenoidów. W przedziale od 0,6 do 0,8  $\mu\text{m}$  natomiast na odbicie wpływają cztery pozostałe parametry poza karotenoidami. Największe znaczenie w zakresie od 0,4 do 0,8  $\mu\text{m}$  ma zielony barwnik.

W badanym zakresie różnica między wartością pierwiastka błędu średniokwadratowego najmniejszą (0,0129) w przypadku poligonu S11, a największą (0,1277) poligonu T6 wyniosła ponad 0,11. W przypadku łąki poligonu T6 wartość błędu przekroczyła 0,1, a na czterech innych poligonach przekroczyła 0,05.

Najmniejszy błąd w przebiegu krzywych spektralnych w całym zakresie widzialnym i bliskiej podczerwieni został stwierdzony w przypadku łąki na poligonie S11, znajdującym się na terenie Ziemi Zakroczymsko-Serockiej (ryc. 8). Łąkę porastały: mietlica pospolita (*Agrostis capillaris*), perz właściwy (*Elymus repens*) oraz w niewielkim stopniu babka zwyczajna (*Plantago maior*) i koniczyna polna (*Trifolium arvense*). Z tego względu określono ją jako łąkę jednorodną i podsiewaną. Była ona uprawiana, ale nieskoszona. Porównując krzywą spektralną modelowaną i zestawioną na podstawie danych terenowych stwierdzono, że niewielkie odchylenia występują w zakresie od 0,4-0,5  $\mu\text{m}$ , w którym odbicie promieniowania było większe niż według pomiarów terenowych.

Największy błąd w zakresie od 0,4 do 0,8  $\mu\text{m}$  wystąpił w przypadku łąki na poprzednio opisanym poligonie T6 (ryc. 5). Wartość pierwiastka błędu średniokwadratowego w tym zakresie wyniosła 0,1277.


Zakres 0,8-1,5  $\mu\text{m}$ . Znacznie większe rozbieżności w przebiegu krzywych spektralnych stwierdzono w zakresie bliskiej podczerwieni – 0,8-1,5  $\mu\text{m}$ . Różnice między wartościami pierwiastka błędu średniokwadratowego były duże. Na wartość odbicia w tym zakresie mają wpływ trzy parametry wejściowe: parametr strukturalny, zawartość wody i materii suchej, ale najwięk-

szy jest wpływ tego ostatniego. W bliskiej podczerwieni wartości błędu miały zakres od 0,0341 (poligon R12) do 0,1453 (poligon P2.2). Różnica między błędami wyniosła 0,1112. Na dziewięciu poligonach wielkość błędu przekroczyła 0,1.

W zakresie bliskiej podczerwieni najmniejszą wartość pierwiastka błędu średniokwadratowego (0,0341) stwierdzono w przypadku łąki na poligonie R12, która była wcześniej opisana (ryc. 4.). Największą wartość pierwiastka błędu średniokwadratowego (0,1453) stwierdzono na łące poligonu P2.2, także scharakteryzowanego wcześniej (ryc. 5.). Jego wartość w zakresie bliskiej podczerwieni wpływała znacząco na skuteczność modelowania całego zakresu od 0,4 do 2,5  $\mu\text{m}$ .

Zakres 1,5-2,5  $\mu\text{m}$ . Największe zróżnicowanie wartości pierwiastka błędu średniokwadratowego wystąpiło jednak w zakresie środkowej podczerwieni (1,5-2,5  $\mu\text{m}$ ) – 0,2204. W tym zakresie spektrum największe znaczenie dla odbicia promieniowania ma obecność w roślinach wody, a mniejsze parametr strukturalny ( $N$ ) i zawartość masy suchej ( $Cw$ ). Największa rozbieżność między modelowaną krzywą spektralną a krzywą „terenową” wystąpiła w przypadku poligonu P2.2. Wartość tego błędu wyniosła tu 0,0315, a najmniejsza była na łące poligonu P2.3 – 0,2519. Na dwunastu poligonach błąd był większy niż 0,1, a na dwóch (P2.2 i S11) przekroczył wartość 0,2.

Najmniejszą rozbieżnością w przebiegu krzywej spektralnej w zakresie środkowej podczerwieni odznaczył się poligon P2.3; wartość pierwiastka błędu średniokwadratowego wyniosła 0,0315 (ryc. 9.). Poligon znajdował się w dolinie Bystrzanki na terenie Pogórza Gorlickiego. Łąka była niejednorodna: porośnięta rajgrasem wyniosłym (*Arrhenatherum elatius*), krwawnikiem pospolitym (*Achillea millefolium*) i koniczycą zwyczajną (*Lotus corniculatus*). Została ona określona jako nieużytkowana (niepodsiewana i niekoszona). Pomimo że był to najmniejszy stwierdzony błąd, to jednak w omawianym

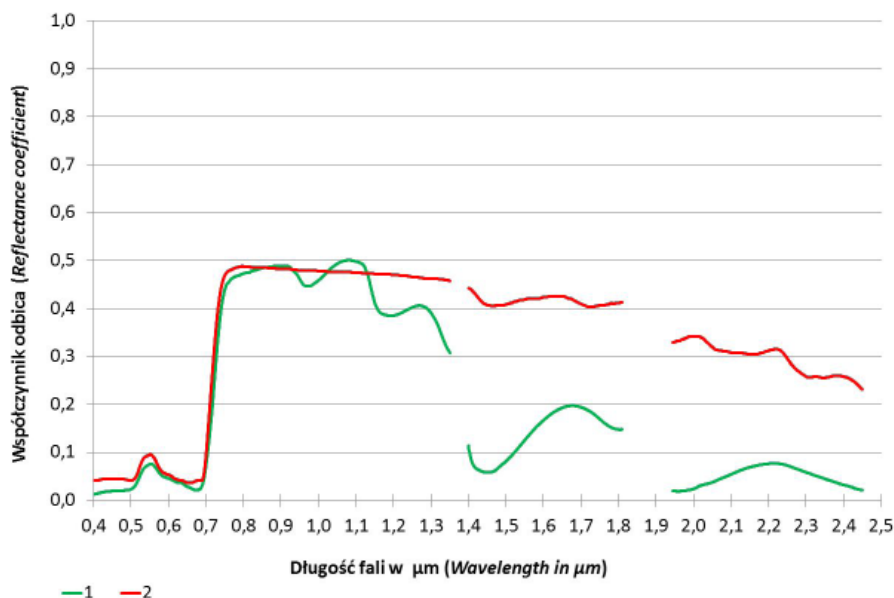


Ryc. 8. Krzywe odbicia spektralnego według danych terenowych (1) i modelowanych z użyciem PROSPECT (2) – poligon S11

Fig. 8. The spectral reflectance from field measurements (1) and modeled using PROSPECT (2) – S11 research area

Ryc. 9. Krzywe odbicia spektralnego według danych terenowych (1) i modelowanych z użyciem PROSPECT (2) – poligon P2.3

Fig. 9. The spectral reflectance from field measurements (1) and modeled using PROSPECT (2) – P2.3 research area



zakresie widma uwidoczniły się różnice w przebiegu obu krzywych spektralnych.

Największy błąd w zakresie 1,5-2,5  $\mu\text{m}$  wyniósł 0,2519; dotyczył on łąki na poprzednio opisanym poligonie P2.2 (ryc. 5).

Podsumowując, wartości pierwiastka błędu średniokwadratowego w symulacjach wzrastały wraz z długością fali. Największe błędy były w zakresie 1,5-2,5  $\mu\text{m}$ , mniejsze w zakresie 0,8-1,5  $\mu\text{m}$ , najmniejsze natomiast w zakresach 0,4-0,6  $\mu\text{m}$  i 0,4-0,8  $\mu\text{m}$ . Najlepszą dokładność modelowania osiągnięto w zakresie 0,4-0,6  $\mu\text{m}$ .

**Skuteczność modelu PROSPECT w modelowaniu charakterystyk spektralnych łąk według ich rodzajów.** Kolejnym etapem badań było badanie uśrednionych wartości pierwiastka błędu średniokwadratowego obliczonego z modelowanych krzywych odbicia spektralnego w stosunku do krzywych uzyskanych z bezpośrednich pomiarów terenowych w zależności od rodzaju łąki. Wszystkie 22 poligony podzielono na łąki uprawiane o zredukowanej biomasy (skoszone) – siedem poligonów, uprawiane o dużej biomasy – dziewięć i nieuprawiane (czyli niekoszone w badanym sezonie wegetacyjnym) – sześć. Łąki nieużytkowane miały złożoną strukturę roślinności, często występowały na nich rośliny kwitnące, które mogły negatywnie wpływać na skuteczność modelowania. Na łąkach nieuprawianych na ogół występuje większa biomasa, najmniejsza natomiast na łąkach skoszonych.

Określono także istotność statystyczną różnic między błędami dotyczącymi trzech rodzajów łąk. Wyróżnione grupy łąk były o różnej liczbie, dlatego istotność statystyczną różnic sprawdzano, używając rangowego nieparametrycznego testu Kruskala-Wallisa dla trzech prób niezależnych. Jeśli różnica była istotna statystycznie, podawano poziom istotności  $p$ . Porównanie trzech rodzajów łąk z użyciem testu Kruskala-Wallisa zostało umieszczone w tabeli 6.

Tab. 6. Porównanie trzech rodzajów łąk: uprawianych o zredukowanej biomasy (1), uprawianych o dużej biomasy (2) i nieuprawianych (3) na podstawie wartości RMSE według modelowania PROSPECT – test Kruskala-Wallisa

Analizowany zakres Wavelength	Rodzaj łąki Type of meadow			Test Kruskala-Wallisa Kruskal-Wallis test		
	1	2	3	df	$\chi^2$	$p$
0,4-2,5 $\mu\text{m}$	14,86	11,67	7,33	2	4,347	0,114
0,4-0,6 $\mu\text{m}$	10,29	10,67	14,17	2	1,405	0,495
0,4-0,8 $\mu\text{m}$	11,00	12,44	10,67	2	0,331	0,848
0,8-1,5 $\mu\text{m}$	13,71	12,11	8,00	2	2,637	0,268
1,5-2,5 $\mu\text{m}$	15,43	11,56	6,83	2	5,662	0,059
Liczebność klas Number of polygons	7	9	6			

Na podstawie tych danych można zauważyć zależność wartości pierwiastka błędu średniokwadratowego od rodzaju łąki (tab. 7.). Podobne zależności występowały w przypadku obu zakresów widma podczerwonego, które mają wpływ na ocenę skuteczności modelowania w całym badanym zakresie widma (0,4-2,5  $\mu\text{m}$ ). Im więcej biomasy znajdowało się na łąkach, tym mniejsze były wartości błędów. W zakresie 0,4-2,5  $\mu\text{m}$  największy błąd stwierdzono na terenie łąk uprawianych o zredukowanej biomasy – 0,1214, nieco mniejszy na obszarach łąk uprawianych o dużej biomasy – 0,1001, a najmniejszy na łąkach nieuprawianych – 0,0712. Największe różnice między wartościami pierwiastka błędu średniokwadratowego wystąpiły w zakresie środkowej podczerwieni:

wielkości błędów wynosiły od 0,0709 w przypadku łąk nieuprawianych do 0,1528 w przypadku łąk skoszonych, czyli o zredukowanej biomase.

Tab. 7. Wartości pierwiastka błędu średniokwadratowego obliczone na podstawie modelowanych krzywych odbicia spektralnego z użyciem PROSPECT względem krzywych opartych na danych terenowych według rodzajów łąk

Tab. 7. The RMSE value calculated using spectral reflectance measured and modelled with PROSPECT regarding to the different meadow types

Badany zakres Wavelength	Rodzaj łąki Type of meadow		
	1	2	3
0,4-2,5 $\mu\text{m}$	0,1214	0,1001	0,0712
0,4-0,6 $\mu\text{m}$	0,0277	0,0259	0,0340
0,4-0,8 $\mu\text{m}$	0,0371	0,0395	0,0435
0,8-1,5 $\mu\text{m}$	0,1075	0,1004	0,0773
1,5-2,5 $\mu\text{m}$	0,1528	0,1153	0,0709

1 – łąki uprawiane o zredukowanej biomase, 2 – łąki uprawiane o dużej biomase; 3 – łąki nieuprawiane

1 – cultivated meadows with reduced amount of biomass; 2 – cultivated meadows with high amount of biomass; 3 – not cultivated meadows

W zakresach 0,4-0,6 i 0,4-0,8  $\mu\text{m}$  różnice w wartościach błędów były znacznie mniejsze. W tych zakresach nieco większe błędy były w przypadku łąk nieuprawianych. Mimo różnic, w żadnym z zakresów nie były one istotne statystycznie, zauważono jedynie tendencję w zakresie środkowej podczerwieni ( $p \leq 0,059$ ), gdzie różnice między wartością błędów były największe.

Na podstawie przeprowadzonych badań można stwierdzić, że inne zależności występują w zakresie widzialnym, a inne w podczerwonym. W modelowaniu w zakresach podczerwonych (0,8-1,5 i 1,5-2,5  $\mu\text{m}$ ) najmniejsze błędy zaznaczają się w przypadku łąk nieuprawianych, a największe łąk uprawianych o zredukowanej biomase. W zakresie widzialnym i fragmencie bliskiej podczerwieni (0,4-0,6 i 0,4-0,8  $\mu\text{m}$ ) różnice w wartościach błędów są niewielkie. Nie zanotowano różnic istotnych statystycznie.

**Skuteczność modelu PROSPECT w modelowaniu charakterystyk spektralnych łąk według parametrów biofizycznych.** Kolejnym etapem badań była ocena skuteczności modelowania odbicia promieniowania w zależności od wartości trzech parametrów biofizycznych: powierzchni projekcyjnej liści (LAI), ilości biomasy świeżej na jednostkę powierzchni terenu i zawartości wody w roślinach. Oceniano, czy różnice między poszczególnymi grupami są istotne statystycznie. Ze względu na niejednakowo liczne kategorie łąk, również w tych badaniach zastosowano rangowy test nieparametryczny Kruskala-Wallisa.

Indeks powierzchni projekcyjnej liści (LAI). Wartości wskaźnika powierzchni projekcyjnej liści podzielono na trzy klasy: od 0 do 2, od 2,01 do 4

i powyżej 4. Wartości zostały umieszczone w tabeli 8, a dokładne porównanie kategorii łąk z użyciem testu Kruskala-Wallisa w tabeli 9. Wartość pierwiastka błędu średniokwadratowego w większości zakresów malała wraz ze zwiększaniem się wartości powierzchni projekcyjnej liści. W całym symulowanym zakresie widma – 0,4-2,5  $\mu\text{m}$ , a szczególnie w podczerwieni błąd wyraźnie zmniejsza się wraz ze wzrostem wartości LAI. Największe różnice stwierdzono w zakresie środkowej podczerwieni. W zakresie widzialnym błąd był największy między 2,01 a 4, a najmniejszy powyżej 4. Różnice nie były istotne statystycznie.

Tab. 8. Wartości pierwiastka błędu średniokwadratowego dotyczące poligonów podzielonych na grupy według wartości powierzchni projekcyjnej liści – symulacja z użyciem PROSPECT

Tab. 8. The RMSE value for meadows with different Leaf Area Index value calculated using PROSPECT model

Powierzchnia projekcyjna liści Leaf Area Index	Pierwiastek błędu średniokwadratowego Root Mean Square Error				
	0,4-2,5 $\mu\text{m}$	0,4-0,6 $\mu\text{m}$	0,4-0,8 $\mu\text{m}$	0,8-1,5 $\mu\text{m}$	1,5-2,5 $\mu\text{m}$
0-2	0,1307	0,0325	0,0396	0,1178	0,1635
2,01-4	0,0986	0,0330	0,0476	0,0987	0,1099
>4	0,0770	0,0197	0,0289	0,0777	0,0879

Tab. 9. Porównanie trzech kategorii łąk wyodrębnionych na podstawie wartości powierzchni projekcyjnej liści używając wartości RMSE według modelowania PROSPECT – test Kruskala-Wallisa

Tab. 9. Comparison of the three types of meadows distinguished by the Leaf Area Index values using RMSE values (PROSPECT modelling) – Kruskal-Wallis test

Analizowany zakres Wavelength	Powierzchnia projekcyjna liści Leaf Area Index			Test Kruskala-Wallisa Kruskal-Wallis test		
	0-2	2,01-4	>4	df	$\chi^2$	p
0,4-2,5 $\mu\text{m}$	16,40	11,60	7,86	2	5,052	0,080
0,4-0,6 $\mu\text{m}$	13,60	11,90	9,43	2	1,273	0,529
0,4-0,8 $\mu\text{m}$	10,80	13,20	9,57	2	1,361	0,506
0,8-1,5 $\mu\text{m}$	16,20	11,90	7,57	2	5,219	0,074
1,5-2,5 $\mu\text{m}$	16,40	11,40	8,14	2	4,720	0,094
Liczebność klas Number of polygons	5	10	7			

Ilość biomasy świeżej. Kolejnym etapem badań oceniających skuteczność modelowania odbicia spektralnego było badanie wartości pierwiastka błędu średniokwadratowego w zależności od ilości biomasy świeżej przypadającej na 1  $\text{m}^2$  (tab. 10.). Dokładne porównanie kategorii łąk z użyciem testu Kruskala-Wallisa przedstawiono w tabeli 11. Biomasa świeża jest sumą suchej roślinności i zawartej w niej w chwili pomiaru wody. Wartości tego parametru podzielono na trzy klasy:

1 – poniżej 0,75; 2 – od 0,76 do 1,5 i 3 – powyżej 1,5 kg na 1 m<sup>2</sup>.

Tab. 10. Wartości pierwiastka błędu średniokwadratowego dotyczące poligonów podzielonych na grupy według ilości biomasy świeżej – symulacja z użyciem PROSPECT

Tab. 10. The RMSE values for meadows with different quantity of fresh biomass calculated using PROSPECT

Ilość biomasy świeżej w kg na 1m <sup>2</sup> <i>Fresh biomass – kg/1m<sup>2</sup></i>	Pierwiastek błędu średniokwadratowego <i>Root Mean Square Error</i>				
	0,4-2,5 μm	0,4-0,6 μm	0,4-0,8 μm	0,8-1,5 μm	1,5-2,5 μm
<0,75	0,1165	0,0301	0,0418	0,1091	0,1416
0,76-1,5	0,1025	0,0320	0,0391	0,1008	0,1163
>1,5	0,0447	0,0188	0,0355	0,0536	0,0404

Tab. 11. Porównanie trzech kategorii łąk wyodrębnionych na podstawie ilości biomasy świeżej używając wartości RMSE według modelowania PROSPECT – test Kruskala-Wallisa

Tab. 11. Comparison of the three types of meadows distinguished by the amount of fresh biomass using RMSE values (PROSPECT modelling) - Kruskal-Wallis test

Analizowany zakres Wavelength	Biomasa świeża w kg na 1m <sup>2</sup> <i>Fresh biomass in kg/1m<sup>2</sup></i>			Test Kruskala-Wallisa <i>Kruskal-Wallis test</i>		
	<0,75	1,76-1,5	>1,5	df	χ <sup>2</sup>	p
0,4-2,5 μm	14,55	11,71	2,75	2	9,690	0,008
0,4-0,6 μm	11,82	13,00	8,00	2	1,562	0,458
0,4-0,8 μm	12,18	9,14	13,75	2	1,524	0,467
0,8-1,5 μm	14,36	11,86	3,00	2	9,014	0,011
1,5-2,5 μm	14,55	11,71	2,75	2	9,690	0,008
Liczebność klas <i>Number of polygons</i>	11	7	4			

W większości zakresów promieniowania, z wyjątkiem fragmentu widma 0,4-0,6 μm, pierwiastek błędu średniokwadratowego wyraźnie malał wraz ze wzrostem biomasy świeżej. Szczególnie duża różnica w wartości pierwiastka błędu średniokwadratowego występowała między drugą (0,76-1,5 kg na 1 m<sup>2</sup>) a trzecią (powyżej 1,5 kg na 1 m<sup>2</sup>) klasą tego parametru. Różnice istotne statystycznie wystąpiły w zakresach: od 0,4 do 2,5 μm ( $p \leq 0,008$ ), od 0,8 do 1,5 μm ( $p \leq 0,011$ ) i 1,5-2,5 μm ( $p \leq 0,008$ ).

Zawartość wody. Skuteczność modelowania rozpatrzono również z punktu widzenia zawartości wody w roślinach. Wartości zostały umieszczone w tabeli 12, a dokładne porównanie kategorii łąk z użyciem testu Kruskala-Wallisa w tabeli 13. Stwierdzono, że we

wszystkich zakresach widma elektromagnetycznego różnice były podobne – wraz ze wzrostem zawartości wody wzrastała wartość uśrednionego pierwiastka błędu średniokwadratowego, a tym samym malała skuteczność modelowania. Największe różnice w skuteczności modelowania zaznaczyły się w środkowej podczerwieni, najmniejsze zaś w zakresie 0,4-0,8 μm. Różnice były istotne statystycznie w całym modelowanym zakresie 0,4-2,5 μm ( $p \leq 0,008$ ), w zakresie 0,8-1,5 μm ( $p \leq 0,016$ ) i 1,5-2,5 μm ( $p \leq 0,02$ ).

Tab. 12. Wartości pierwiastka błędu średniokwadratowego dotyczące poligonów podzielonych na grupy według zawartości wody – symulacja z użyciem PROSPECT

Tab. 12. The RMSE value for meadows with different water content calculated using PROSPECT

Zawartość wody <i>Water content</i>	Pierwiastek błędu średniokwadratowego <i>Root Mean Square Error</i>				
	0,4-2,5 μm	0,4-0,6 μm	0,4-0,8 μm	0,8-1,5 μm	1,5-2,5 μm
< 70%	0,0588	0,0190	0,0340	0,0677	0,0595
70,1- 80%	0,0898	0,0284	0,0409	0,0905	0,1026
> 80%	0,1255	0,0336	0,0419	0,1148	0,1516

Tab. 13. Porównanie trzech kategorii łąk wyodrębnionych na podstawie zawartości wody używając wartości RMSE według modelowania PROSPECT – test Kruskala-Wallisa

Tab. 13. Comparison of the three types of meadows distinguished by different water content using RMSE values (PROSPECT modelling) – Kruskal-Wallis test

Analizowany zakres Wavelength	Zawartość wody w % <i>Water content in %</i>			Test Kruskala-Wallisa <i>Kruskal-Wallis test</i>		
	<70	70,1-80	>80	df	χ <sup>2</sup>	p
0,4-2,5 μm	4,60	10,71	15,50	2	9,542	0,008
0,4-0,6 μm	8,60	12,29	12,40	2	1,292	0,524
0,4-0,8 μm	12,80	12,29	10,30	2	0,644	0,725
0,8-1,5 μm	5,20	10,57	15,30	2	8,274	0,016
1,5-2,5 μm	5,40	10,57	15,20	2	7,802	0,020
Liczebność klas <i>Number of polygons</i>	5	7	10			

Wyniki wykonanych badań dotyczące modelowania odbicia promieniowania z użyciem PROSPECT pozwalają stwierdzić, że im większe są wartości parametru LAI i biomasy świeżej, tym mniejsza jest wartość pierwiastka błędu średniokwadratowego. Szczególnie widoczne jest to w zakresie środkowej podczerwieni. Odwrotna tendencja występuje w przypadku zawartości wody – im większa jej zawartość, tym większe są wartości błędu, a tym samym mniejsza skuteczność modelowa-

nia. W zakresie podczerwieni różnice w wartości błędu w klasach określających zawartość wody i biomasę są istotne statystycznie. W widzialnym zakresie widma nie stwierdza się różnic istotnych statystycznie w odniesieniu do żadnego z badanych parametrów biofizycznych.

### Symulacja charakterystyk spektralnych na poziomie pokrywy roślinnej z użyciem modelu PROSAIL

*Simulation of the spectral reflectances on the canopy level with the PROSAIL model*

Przedstawiono tu badania odbicia spektralnego i zestawianych na ich podstawie krzywych otrzymanych za pomocą modelowania danych z użyciem modelu PROSAIL według tego samego schematu, co w przypadku PROSPECT.

**Skuteczność modelu PROSAIL w modelowaniu charakterystyk spektralnych łąk badanych poligonów w wybranych zakresach widma.** Skuteczność modelowania odbicia spektralnego i krzywych spektralnych z użyciem modelu PROSAIL określano w ten sam sposób, jak w przypadku modelu PROSPECT.

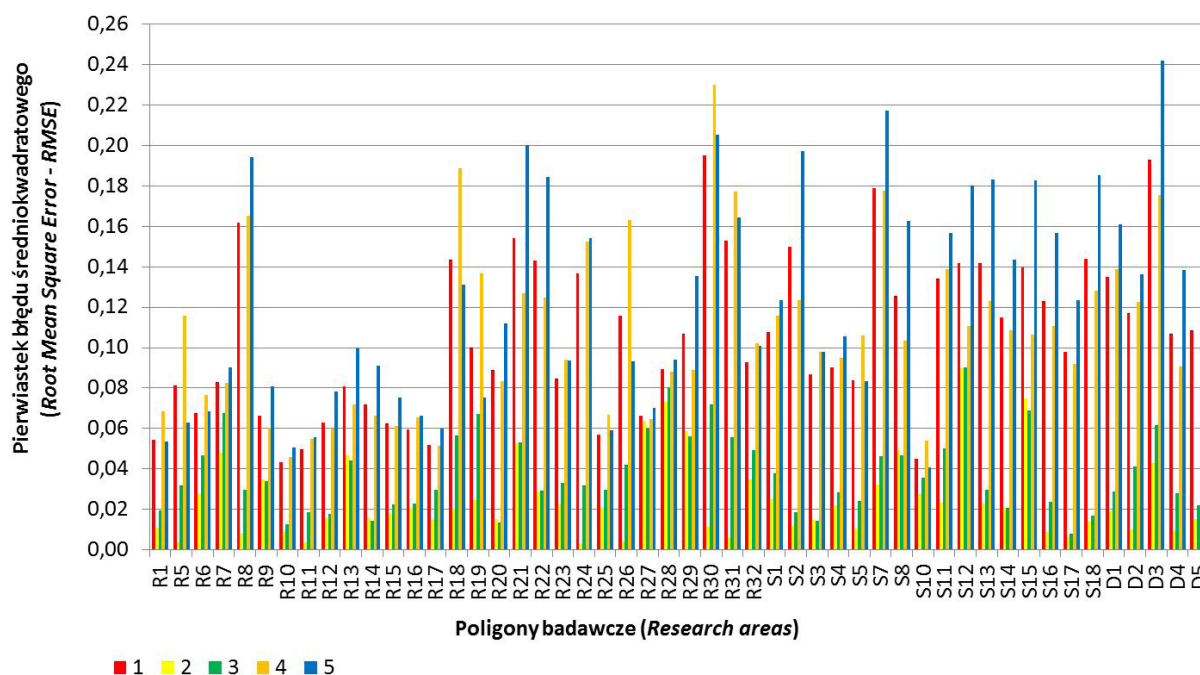
Łączny średni pierwiastek błędu średniokwadratowego w zakresie widma od 0,4 do 2,5  $\mu\text{m}$  w stosunku do pomiarów terenowych wyniósł 0,1058. Największy błąd stwierdzono w zakresie środkowej podczerwieni (0,123), nieco mniejszy (0,1072) w bliskiej podczerwieni. W zakresie od 0,4 do 0,6  $\mu\text{m}$  średni błąd wyniósł 0,0253, a w zakresie 0,4-0,8  $\mu\text{m}$  0,0376.

Następnie omówiono wartości pierwiastka błędu średniokwadratowego odbicia spektralnego promieniowania od łąk na poszczególnych poligonach w wybranych zakresach widma elektromagnetycznego (ryc. 10).

Zakres 0,4-2,5  $\mu\text{m}$ . W tym zakresie średni błąd dla łąk wszystkich badanych poligonów wyniósł 0,1058. Wahał się on od 0,0433 na poligonie R10 do 0,195 na poligonie R30. Na 25 poligonach wartość pierwiastka błędu średniokwadratowego przekraczała 0,1, a na 5 (R8, R21, R30, R31 i S7) wyniosła ponad 0,15.

Krzywa modelowana o najmniejszym odchyleniu od krzywej terenowej w zakresie 0,4-2,5  $\mu\text{m}$  była w przypadku poligonu R10 (ryc. 11.); błąd wyniósł tu 0,0433. Była to łąka położona na Równinie Mszczonowskiej porośnięta bardzo zróżnicowaną roślinnością, w tym trawami, w niewielkim stopniu koniczyną i kwiatami. Była ona określona jako niejednorodna, uprawiana i niepodsiwiana. Wartości modelowane bardzo niewiele różniły się od zmierzonych w terenie, co jest szczególnie widoczne w widzialnym zakresie widma. Jednocześnie, mimo występujących dość dużych różnic, poligon miał najmniejszy błąd w zakresie środkowej podczerwieni (0,0459). Różnice w wielkości odbicia między krzywą modelowaną a „terenową” były spowodowane prawdopodobnie zbyt małą wartością parametru określającego zawartość wody ( $C_w$ ).

Największą wartość pierwiastka błędu średniokwadratowego (0,195) w zakresie 0,4-2,5  $\mu\text{m}$  stwierdzono w przypadku poligonu R30 (ryc. 12.). Łąka znajdowała się na Równinie Mszczonowskiej. Rosły tu gatunki wie-



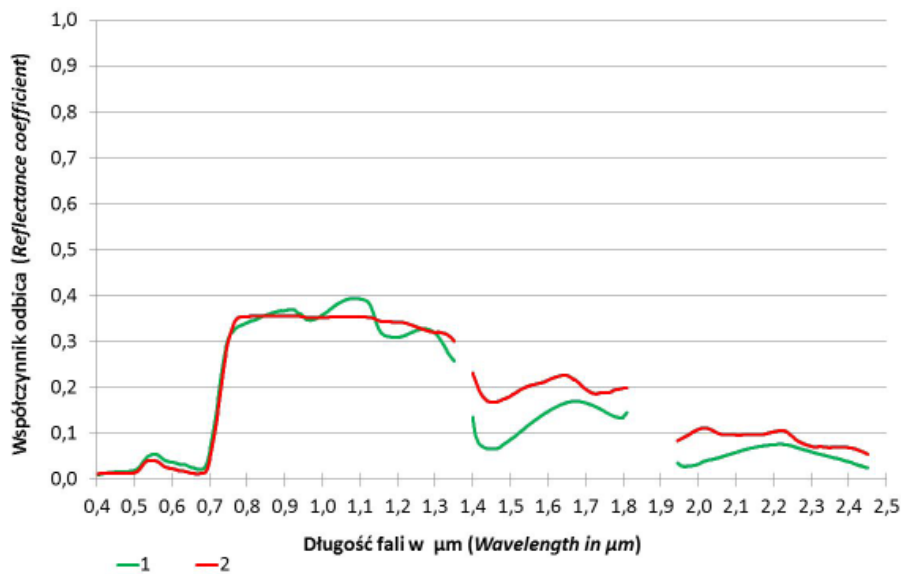
Ryc. 10. Wartości pierwiastka błędu średniokwadratowego między krzywymi odbicia spektralnego modelowanymi z użyciem PROSAIL i uzyskanymi z pomiarów terenowych. Zakresy spektrum: 1 – 0,4-2,5  $\mu\text{m}$ ; 2 – 0,4-0,6  $\mu\text{m}$ ; 3 – 0,4-0,8  $\mu\text{m}$ ; 4 – 0,8-1,5  $\mu\text{m}$ ; 5 – 1,5-2,5  $\mu\text{m}$

Fig. 10. The values of Root Mean Square Error calculated using data obtained in spectral reflectance field measurements and spectral reflectance modelled using PROSAIL. Wavelength: 1 – 0,4-2,5  $\mu\text{m}$ ; 2 – 0,4-0,6  $\mu\text{m}$ ; 3 – 0,4-0,8  $\mu\text{m}$ ; 4 – 0,8-1,5  $\mu\text{m}$ ; 5 – 1,5-2,5  $\mu\text{m}$



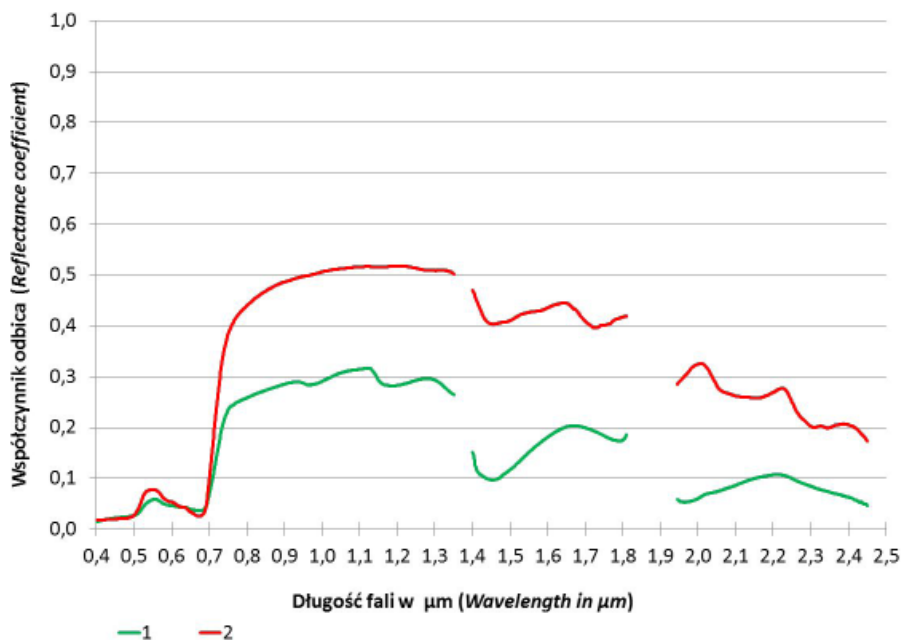
Ryc. 11. Krzywe odbicia spektralnego według danych terenowych (1) i modelowanych z użyciem PROSAIL (2) – poligon R10

Fig. 11. The spectral reflectance from field measurements (1) and modeled using PROSAIL (2) – R10 research area



Ryc. 12. Krzywe odbicia spektralnego według danych terenowych (1) i modelowanych z użyciem PROSAIL (2) – poligon R30

Fig. 12. The spectral reflectance from field measurements (1) and modeled using PROSAIL (2) – R30 research area




chlinowate i koniczyna. Łąka była podsiewana, koszona i określono ją jako niejednorodną, głównie ze względu na obecność koniczyny. Dość dobrze modelowane były wartości odbicia promieniowania w zakresie widzialnym, natomiast w zakresie podczerwonym wartości znacznie odbiegały od wzorcowej krzywej. Różnica w wartościach odbicia sięgała 0,3. Na poligonie R30 był także największy błąd w zakresie bliskiej podczerwieni, wynoszący 0,2301. Na błędy w modelowaniu wpływała zarówno zbyt mała wartość parametru określającego zawartość wody ( $C_w$ ), jak i zbyt duże wartości wskaźnika powierzchni projekcyjnej liści (LAI) i zawartości masy suchej ( $C_m$ ). Krzywa modelowana miała znacząco większe wartości współczynnika odbicia w porównaniu do pobranej w terenie.

Zakres 0,4-0,6  $\mu\text{m}$ . Dość niewielkie wartości błędu średniokwadratowego występowały w zakresie widzialnym od 0,4 do 0,6  $\mu\text{m}$ . Najmniejszy błąd – 0,0028


stwierdzono w przypadku poligonu R24, a największy (0,0897) poligonu S12. Na sześciu poligonach: R21, R27, R28, R29, S12 i S15, wartość pierwiastka błędu średniokwadratowego przekraczała 0,05.

W przedziale widma od 0,4 do 0,6  $\mu\text{m}$  błędy były najniższe wśród wszystkich zakresów. Najmniejszy pierwiastek błędu średniokwadratowego w tym zakresie był na poligonie R24, gdzie wyniósł 0,0028 (ryc. 13.). Łąka znajdowała się na poligonie na Równinie Mszczonowskiej. Była to łąka uprawiana – niejednorodna i niedawno skoszona. Porośnięta była trzcinnikiem piaskowym (*Calamagrostis epigeios*), wiechliną łąkową (*Poa pratensis*), lyszcem polnym (*Gypsophila muralis*), wyką płotową (*Vicia sepium*), prosownicą rozpięzchłą (*Milium effusum*) i mietlicą pospolitą (*Agrostis capillaris*). W omawianym zakresie spektrum krzywa modelowana i mierzona w terenie miały prawie identyczny przebieg.



Ryc. 13. Krzywe odbicia spektralnego według danych terenowych (1) i modelowanych z użyciem PROSAIL (2) – poligon R24

Fig. 13. The spectral reflectance from field measurements (1) and modeled using PROSAIL (2) – R24 research area



Ryc. 14. Krzywe odbicia spektralnego według danych terenowych (1) i modelowanych z użyciem PROSAIL (2) – poligon S12

Fig. 14. The spectral reflectance from field measurements (1) and modeled using PROSAIL (2) – S12 research area

W zakresie 0,4-0,6  $\mu\text{m}$  najgorzej były modelowane wartości odbicia spektralnego w przypadku poligonu S12 (ryc. 14.); wartość pierwiastka błędu średniokwadratowego wyniosła 0,0897. Badana łąka znajdowała się na Ziemi Zakroczymsko-Serockiej. Była określona jako jednorodna. Porastał ją rajgras wyniosły (*Arrhenatherum elatius*) i mietlica pospolita (*Agrostis capillaris*). Była uprawiana – niepodsiwiana i koszona. Największe różnice między dwiema krzywymi wystąpiły w zakresie od 0,5 do 0,6  $\mu\text{m}$ , gdzie wartości modelowane były wyraźnie przeszacowane.

Zakres 0,4-0,8  $\mu\text{m}$ . W tym zakresie widma wartości pierwiastka błędu średniokwadratowego także były niewielkie: od 0,008 na poligonie S17 do 0,09 na poligonie S12. Na trzynastu poligonach wartość pierwiastka błędu średniokwadratowego przekroczyła 0,05.

W całym zakresie widma 0,4-0,8  $\mu\text{m}$  najlepsze rezultaty uzyskano w odniesieniu do poligonu S17 (ryc. 15.).

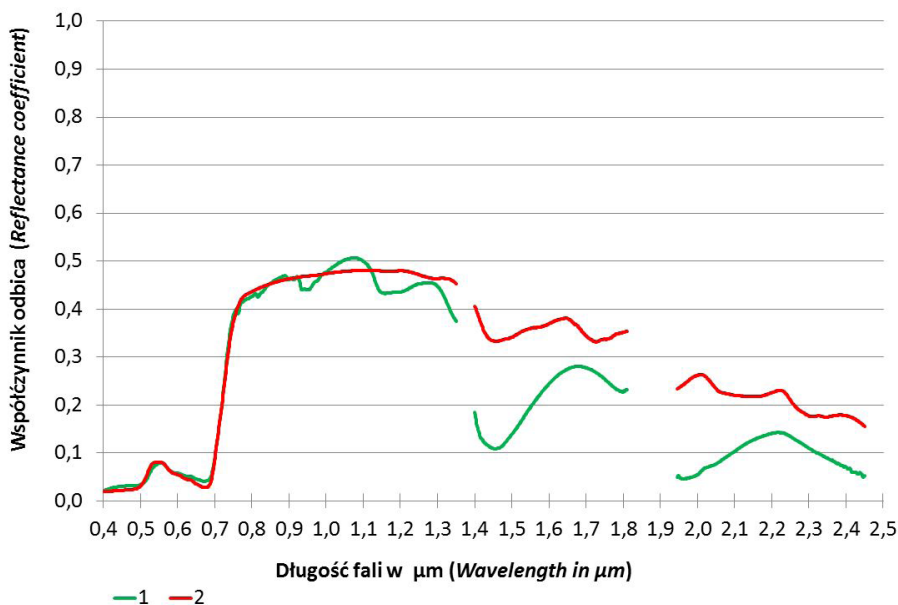
Wartość pierwiastka błędu średniokwadratowego wyniosła 0,008. Na łąkach tego poligonu rosły – mietlica pospolita (*Agrostis capillaris*) i w niewielkich ilościach szczaw zwyczajny (*Rumex acetosa*), dlatego łąkę można było uznać za jednorodną. Obszar znajdował się na Ziemi Zakroczymsko-Serockiej. Łąka była uprawiana – koszona, ale niepodsiwiana. W zakresie widzialnym przebieg krzywej modelowanej był bardzo zbliżony do krzywej „terenowej”. Niewielkie różnice występowały w zakresie od 0,4 do 0,5  $\mu\text{m}$  i od 0,65 do 0,7  $\mu\text{m}$ , w których wartości modelowane były niższe niż te pochodzące z pomiarów terenowych.

Największą wartość (0,09) pierwiastek błędu średniokwadratowego w zakresie 0,4-0,8  $\mu\text{m}$  miał w przypadku poligonu S12, już wcześniej opisanego (ryc. 14.).

Zakres 0,8-1,5  $\mu\text{m}$ . Na dość duże wartości pierwiastka błędu średniokwadratowego w całym optycznym zakresie promieniowania wpłynęła głównie wielkość

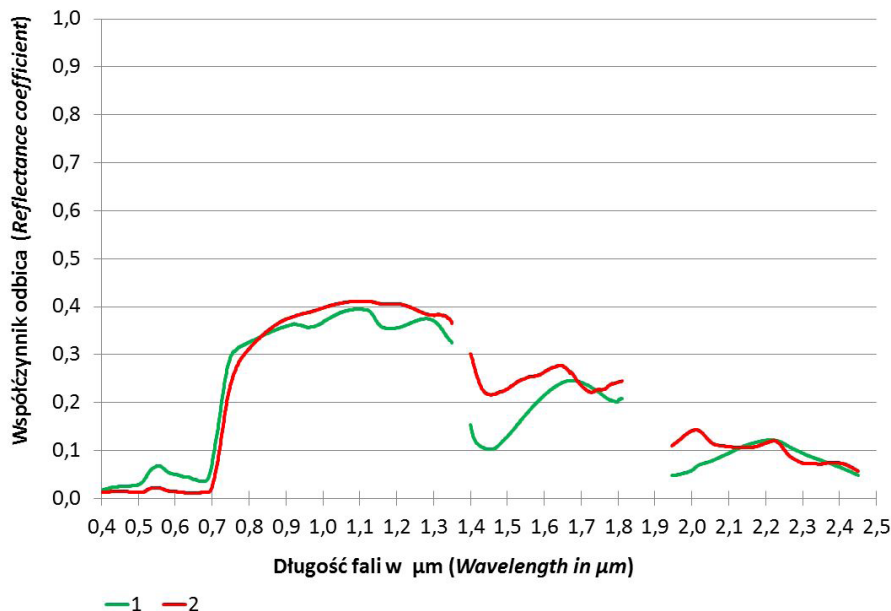
Ryc. 15. Krzywe odbicia spektralnego według danych terenowych (1) i modelowanych z użyciem PROSAIL (2) – poligon S17

Fig. 15. The spectral reflectance from field measurements (1) and modeled using PROSAIL (2) – S17 research area



Ryc. 16. Krzywe odbicia spektralnego według danych terenowych (1) i modelowanych z użyciem PROSAIL (2) – poligon S10

Fig. 16. The spectral reflectance from field measurements (1) and modeled using PROSAIL (2) – S10 research area



błędu w zakresie podczerwonym. Wartość RMSE w bliskiej podczerwieni wynosiła od 0,0495 na łące poligonu R10 do 0,2301 na łące poligonu R30. W przypadku 27 poligonów wartość błędu przekroczyła 0,1, a na 7 poligonach (R8, R18, R26, R30, R31, S7 i D3) była wyższa od 0,15.

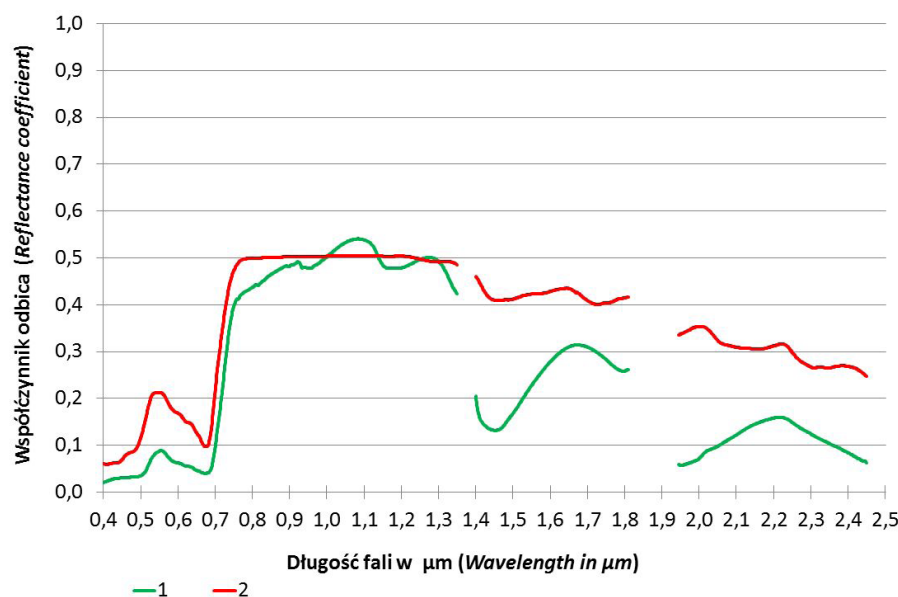
W zakresie bliskiej podczerwieni najmniejszy (0,0459) pierwiastek błędu średniokwadratowego był w przypadku łąki na poligonie R10, opisanej poprzednio (ryc. 11.), największy natomiast (0,2301) na poligonie R30 (ryc. 13).

Zakres 1,5-2,5 µm. Największe błędy w modelowaniu krzywych odbicia spektralnego wystąpiły w zakresie środkowej podczerwieni. W zakresie tym na odbicie promieniowania dominujący wpływ ma zawartość wody. Wartości pierwiastka błędu średniokwadratowego mieściły się w przedziale od 0,0407 na poligonie S10 do 0,2421 na poligonie D3. Na 21 poligonach wartość pier-

wiastka błędu średniokwadratowego była mniejsza niż 0,1. Na czterech poligonach (R21, R30, S7 i D3) wartość błędu przekroczyła 0,2.

Krzywą o najmniejszym pierwiastku błędu średniokwadratowego (0,0407) w tym zakresie zanotowano dla łąki na poligonie S10 (ryc. 16.). Wartości modelowane znacznie różniły się od zmierzonych w terenie. Różnica między wartościami współczynnika odbicia zbliżała się do 0,1 w zakresie 1,5-1,6 µm. W zakresie fal od 1,5 do 1,7 µm i od 1,75 do 2,125 µm wartości modelowane były przeszacowane. Łąka na poligonie S10 znajdowała się na Ziemi Zakroczymsko-Serockiej. Była uprawiana: podsiewana, a także o zredukowanej przez skoszenie biomasy. Była ona dość jednorodna – porośnięta mietlicą pospolitą (*Agrostis capillaris*), w niewielkim stopniu koniczyną łąkową (*Trifolium pratense*) i perzem właściwym (*Elymus repens*).

Najgorzej modelowana krzywa odbicia spektralnego



Ryc. 17. Krzywe odbicia spektralnego według danych terenowych (1) i modelowanych z użyciem PROSAIL (2) – poligon D3  
 Fig. 17. The spectral reflectance from field measurements (1) and modeled using PROSAIL (2) – D3 research area

w zakresie środkowej podczerwieni dotyczy poligonu D3, znajdującego się w Dolinie Środkowej Wisły. Wartość pierwiastka błędu średniokwadratowego wyniosła tu 0,2421 (ryc. 17.). Łąka była porośnięta mietlicą pospolitą (*Agrostis capillaris*), wiechliną łąkową (*Poa pratensis*), koniczyną łąkową (*Trifolium pratense*) i mniszkiem lekarskim (*Taraxacum officinale*). Była intensywnie użytkowana – podsiewana i skoszona. W całym badanym zakresie widma wartości modelowane znacznie przekraczały te uzyskane w pomiarach terenowych. Różnice między wartościami współczynników odbicia były większe od 0,3 – największa rozbieżność była w zakresie około 1,5 µm i malała wraz z długością fali.

**Skuteczność modelu PROSAIL w modelowaniu charakterystyk spektralnych łąk według ich rodzajów.** Kolejnym etapem badań było porównanie wartości pierwiastka błędu średniokwadratowego w zależności od rodzaju łąki. Badane 50 poligonów podzielono na trzy rodzaje w zależności od ich użytkowania: uprawiane o biomase zredukowanej przez skoszenie (11 poligonów), uprawiane o dużej biomase – koszone (29 poligonów) i nieuprawiane, czyli niekoszone w ogóle (10 poligonów). Badano różnice między uśrednionymi wartościami pierwiastka błędu średniokwadratowego. Tak jak przy badaniach z użyciem modelu PROSPECT, istotność statystyczną różnic między danymi modelowanymi a uzyskanymi bezpośrednio w terenie sprawdzono na trzech niezależnych próbach, używając testu nieparametrycznego Kruskala-Wallisa. Porównanie trzech rodzajów łąk z użyciem testu Kruskala-Wallisa umieszczono w tabeli 14.

W całym zakresie widma (0,4-2,5 µm) i w dwóch zakresach podczerwieni (0,8-1,5 i 1,5-2,5 µm) wystąpiła ta sama zależność między wielkością błędów (tab. 15.). Najmniejsze wartości uśrednionego pierwiastka błędu średniokwadratowego stwierdzono w przypadku łąk nieuprawianych, gdzie roślinność była najbardziej zróżnicowana, a biomasa była duża. Największe błędy występowały na terenie łąk uprawianych o skoszonej,

czyli zredukowanej biomase. W zakresie od 0,4 do 2,5 µm wartość pierwiastka błędu średniokwadratowego łąk w przypadku nieuprawianych wyniosła 0,0874, uprawianych nieskoszonych – 0,1038, a uprawianych i skoszonych – 0,1277.

Tab. 14. Porównanie trzech rodzajów łąk: uprawianych o zredukowanej biomase (1), uprawianych o dużej biomase (2) i nieuprawianych (3) na podstawie wartości RMSE według modelowania PROSAIL – test Kruskala-Wallisa  
 Tab. 14. The comparison of three types of grasslands: cultivated with reduced biomass (1), cultivated with high amount of biomass (2) and not cultivated (3) using RMSE values (PROSAIL modeling) – Kruskal-Wallis test

Analizowany zakres Wavelength	Rodzaj łąki Type of meadow			Test Kruskala-Wallisa Kruskal-Wallis test		
	1	2	3	df	$\chi^2$	p
0,4-2,5 µm	32,91	25,03	18,70	2	5,047	0,080
0,4-0,6 µm	24,45	26,79	22,90	2	0,603	0,740
0,4-0,8 µm	25,73	25,38	25,60	2	0,005	0,997
0,8-1,5 µm	32,45	24,00	22,20	2	3,323	0,190
1,5-2,5 µm	32,91	25,76	16,60	2	6,578	0,037
Liczebność klas Number of polygons	11	29	10			

W zakresach 0,4-0,6 i 0,4-0,8 µm różnice między wielkością błędów były bardzo niewielkie i nieistotne statystycznie. Największa różnica w wartościach pierwiastka błędu średniokwadratowego między rodzajami łąk wyniosła 0,0045 w zakresie 0,4-0,6 µm, a 0,0019 w zakresie 0,4-0,8 µm.

Największe wartości pierwiastka błędu średniokwadratowego wystąpiły w zakresie środkowej podczerwieni

Tab. 15. Wartości pierwiastka błędu średniokwadratowego obliczone na podstawie modelowanych krzywych odbicia spektralnego z użyciem PROSAIL względem krzywych opartych na danych terenowych według rodzajów łąk

Tab. 15. The RMSE value calculated using spectral reflectance measured and modelled with PROSAIL regarding to the different meadow types

Badany zakres Wavelength	Rodzaj łąki Type of meadow		
	1	2	3
0,4-2,5 $\mu\text{m}$	0,1277	0,1038	0,0874
0,4-0,6 $\mu\text{m}$	0,0243	0,0267	0,0222
0,4-0,8 $\mu\text{m}$	0,0374	0,0382	0,0363
0,8-1,5 $\mu\text{m}$	0,1270	0,1030	0,0976
1,5-2,5 $\mu\text{m}$	0,1527	0,1221	0,0928

1 – łąki uprawiane o zredukowanej biomase, 2 – łąki uprawiane o dużej biomase; 3 – łąki nieuprawiane

1 – cultivated meadows with reduced amount of biomass; 2 – cultivated meadows with high amount of biomass; 3 – not cultivated meadows

na łąkach skoszonych. Średnia wartości błędu wyniosła tu 0,1527, a na łąkach nieuprawianych – 0,0928. W zakresie tym, różnice były istotne statystycznie ( $p \leq 0,037$ ). W pozostałych zakresach nie występowały różnice istotne statystycznie.

Można stwierdzić, że w zakresie podczerwieni błąd jest największy w przypadku łąk uprawianych o sztucznie zredukowanej biomase. W zakresie widzialnym różnice w skuteczności modelowania są nieistotne.

**Skuteczność modelu PROSAIL w modelowaniu charakterystyk spektralnych łąk według parametrów biofizycznych.** W kolejnym etapie zbadano wartości pierwiastka błędu średniokwadratowego odnośnie do trzech parametrów biofizycznych. Wskaźniki charakteryzujące wartości tych parametrów zostały podzielone w każdym przypadku na trzy klasy ich wartości. Zbadano również istotność statystyczną różnic w poszczególnych zakresach spektralnych widma za pomocą testu rangowego Kruskala-Wallisa.

Indeks powierzchni projekcyjnej liści (LAI). Na początku zbadano skuteczność modelowania na podstawie średnich wartości pierwiastka błędu średniokwadratowego odnośnie do wartości wskaźnika powierzchni projekcyjnej liści (LAI) (tab. 16.). Dokładne porównanie kategorii łąk z użyciem testu Kruskala-Wallisa umieszczono w tabeli 17.

Największą średnią wartość pierwiastka błędu średniokwadratowego (0,1456) stwierdzono na łąkach w klasie najniższych wartości LAI – od 0 do 2. Wraz ze wzrostem wartości wskaźnika powierzchni projekcyjnej liści błąd malał. Różnice w tym zakresie osiągnęły bardzo wysoki poziom istotności statystycznej ( $p \leq 0,0005$ ). Na wartości błędów w zakresie widma 0,4-2,5  $\mu\text{m}$  dominujący wpływ miały błędy w zakresach podczerwieni, w których wystąpił ten sam kierunek zmian. Największa

Tab. 16. Wartości pierwiastka błędu średniokwadratowego dotyczące poligonów podzielonych na grupy według wartości powierzchni projekcyjnej liści – symulacja z użyciem PROSAIL

Tab. 16. The RMSE value for meadows with different Leaf Area Index value calculated using PROSAIL model

Powierzchnia projekcyjna liści Leaf Area Index	Pierwiastek błędu średniokwadratowego Root Mean Square Error				
	0,4-2,5 $\mu\text{m}$	0,4-0,6 $\mu\text{m}$	0,4-0,8 $\mu\text{m}$	0,8-1,5 $\mu\text{m}$	1,5-2,5 $\mu\text{m}$
	0-2	0,1456	0,0220	0,0316	0,1353
2,01-4	0,1100	0,0184	0,0393	0,1230	0,1187
>4	0,0832	0,0331	0,0388	0,0782	0,1000

Tab. 17. Porównanie trzech kategorii łąk wyodrębnionych na podstawie wartości powierzchni projekcyjnej liści używając wartości RMSE według modelowania PROSAIL – test Kruskala-Wallisa

Tab. 17. Comparison of the three types of meadows distinguished by the Leaf Area Index values using RMSE values (PROSAIL modelling) - Kruskal-Wallis test

Analizowany zakres Wavelength	Powierzchnia projekcyjna liści Leaf Area Index			Test Kruskala-Wallisa Kruskal-Wallis test		
	0-2	2,01-4	>4	df	$\chi^2$	p
0,4-2,5 $\mu\text{m}$	41,30	26,20	16,90	2	18,755	0,000
0,4-0,6 $\mu\text{m}$	24,80	20,70	30,65	2	4,688	0,096
0,4-0,8 $\mu\text{m}$	22,50	26,70	25,80	2	0,568	0,753
0,8-1,5 $\mu\text{m}$	39,00	29,80	14,45	2	21,809	0,000
1,5-2,5 $\mu\text{m}$	42,10	23,35	19,35	2	16,962	0,000
Liczebność klas Number of polygons	10	20	20			

wartość błędów była na łąkach o najniższych wartościach LAI: w zakresie bliskiej podczerwieni – 0,1353, a w środkowej podczerwieni – 0,1821. W zakresach tych różnice były istotne statystycznie ( $p \leq 0,0005$ ). W zakresach 0,4-0,6 i 0,4-0,8  $\mu\text{m}$  różnice między błędami były znacznie mniejsze niż w zakresie podczerwieni, a także nieistotne statystycznie. W przedziale widma 0,4-0,6  $\mu\text{m}$  największy błąd stwierdzono na łąkach o wartościach LAI powyżej 4, a w zakresie 0,4-0,8  $\mu\text{m}$  – na łąkach o wartościach LAI od 2,01 do 4.

Ilość biomasy świeżej. Następnie określono skuteczność modelowania w zależności od ilości biomasy świeżej na 1  $\text{m}^2$  (tab. 18.). Dokładne porównanie kategorii łąk z użyciem testu Kruskala-Wallisa umieszczono w tabeli 19. Na ilość biomasy świeżej wpływa zawartość wody, której udział w ogólnej masie roślinności stanowi około 70-80%.

W prawie każdym z opisywanych zakresów promieniowania błąd malał wraz ze wzrostem biomasy świeżej. Wyjątkiem był zakres widma od 0,4 do 0,6  $\mu\text{m}$ , w którym tendencja była odwrotna. Największe różnice w wartości

Tab. 18. Wartości pierwiastka błędu średniokwadratowego dotyczące poligonów podzielonych na grupy według ilości biomasy świeżej – symulacja z użyciem PROSAIL

Tab. 18. The RMSE value for meadows with different quantity of fresh biomass calculated using PROSAIL

Biomasa świeża w Fresh biomass kg/1 m <sup>2</sup>	Pierwiastek błędu średniokwadratowego Root Mean Square Error				
	0,4-2,5 μm	0,4-0,6 μm	0,4-0,8 μm	0,8-1,5 μm	1,5-2,5 μm
<0,75	0,1267	0,0240	0,0406	0,1309	0,1462
0,76-1,5	0,0952	0,0263	0,0362	0,0951	0,1112
>1,5	0,0699	0,0269	0,0326	0,0669	0,0835

Tab. 19. Porównanie trzech kategorii łąk wyodrębnionych na podstawie ilości biomasy świeżej używając wartości RMSE według modelowania PROSAIL – test Kruskala-Wallisa

Tab. 19. Comparison of the three types of meadows distinguished by different amount of fresh biomass using RMSE values (PROSAIL modelling) - Kruskal-Wallis test

Analizowany zakres Wavelength	Biomasa świeża w kg na 1m <sup>2</sup> Fresh biomass in kg/1m <sup>2</sup>			Test Kruskala-Wallisa Kruskal-Wallis test		
	<0,75	1,76-1,5	>1,5	df	χ <sup>2</sup>	p
0,4-2,5 μm	33,21	22,18	11,22	2	16,228	0,000
0,4-0,6 μm	23,17	27,82	27,33	2	1,189	0,552
0,4-0,8 μm	27,29	25,35	21,00	2	1,222	0,543
0,8-1,5 μm	34,50	21,41	9,22	2	21,707	0,000
1,5-2,5 μm	31,71	22,71	14,22	2	10,365	0,006
Liczebność klas Number of polygons	24	17	9			

uśrednionych pierwiastków błędu średniokwadratowego wystąpiły w podczerwieni. Podobnie jak w przypadku wskaźnika powierzchni projekcyjnej liści, tak i w tym przypadku różnice istotne statystycznie między wielkościami błędów dotyczyły przedziałów widma: 0,4-2,5 μm ( $p \leq 0,0005$ ), 0,8-1,5 μm ( $p \leq 0,0005$ ) i 1,5-2,5 μm ( $p \leq 0,006$ ).

Zawartość wody. Ostatnim z omawianych parametrów biofizycznych z punktu widzenia skuteczności modelowania była zawartość wody w roślinie (tab. 20.). Dokładne porównanie kategorii łąk z użyciem testu Kruskala-Wallisa umieszczono w tabeli 21.

W całym zakresie (od 0,4 do 2,5 μm) i w obu zakresach promieniowania podczerwonego wraz ze wzrostem zawartości wody rosła wartość pierwiastka błędu średniokwadratowego. Na terenach łąk o zawartości wody w roślinach poniżej 70% wielkość błędów wyniosła 0,0811, a na łąkach o zawartości wody powyżej 80% – 0,1387. Największe różnice w wielkości błędów stwierdzono w środkowej podczerwieni, gdzie zawartość wody jest

Tab. 20. Wartości pierwiastka błędu średniokwadratowego dotyczące poligonów podzielonych na grupy według zawartości wody – symulacja z użyciem PROSAIL

Tab. 20. The RMSE value for meadows with different water content calculated using PROSAIL

Zawartość wody Water content	Pierwiastek błędu średniokwadratowego Root Mean Square Error				
	0,4-2,5 μm	0,4-0,6 μm	0,4-0,8 μm	0,8-1,5 μm	1,5-2,5 μm
< 70%	0,0811	0,0306	0,0421	0,0886	0,0863
70,1-80%	0,1143	0,0231	0,0359	0,1145	0,1353
> 80%	0,1387	0,0193	0,0323	0,1289	0,1735

Tab. 21. Porównanie trzech kategorii łąk wyodrębnionych na podstawie zawartości wody używając wartości RMSE według modelowania PROSAIL – test Kruskala-Wallisa

Tab. 21. Comparison of the three types of meadows distinguished by different water content using RMSE values (PROSAIL modelling) - Kruskal-Wallis test

Analizowany zakres Wavelength	Zawartość wody w % Water content in %			Test Kruskala-Wallisa Kruskal-Wallis test		
	<70	70,1-80	>80	df	χ <sup>2</sup>	p
0,4-2,5 μm	16,17	28,88	37,43	2	13,410	0,001
0,4-0,6 μm	28,89	23,92	22,43	2	1,577	0,454
0,4-0,8 μm	28,17	24,96	20,57	2	1,437	0,488
0,8-1,5 μm	18,28	27,80	35,86	2	8,574	0,014
1,5-2,5 μm	14,94	29,32	39,00	2	17,158	0,000
Liczebność klas Number of polygons	18	25	7			

dominującym parametrem wpływającym na wielkość współczynnika odbicia. Różnice między trzema grupami łąk były istotne statystycznie. W zakresie widma 0,4-2,5 μm poziom istotności statystycznej różnic w wielkościach błędów wyniósł  $p \leq 0,001$ , w bliskiej podczerwieni (0,8-1,5 μm) –  $p \leq 0,014$ , a w środkowej podczerwieni (1,5-2,5 μm) –  $p \leq 0,0005$ . W przypadku zakresów 0,4-0,6 μm i 0,4-0,8 μm tendencja była odwrotna – im większa zawartość wody, tym mniejsza wartość błędów, a tym samym skuteczniejsze modelowanie. Różnice w tych zakresach nie były istotne statystycznie.

Na podstawie przeprowadzonych badań stwierdzono, że łąki o większej ilości biomasy świeżej charakteryzują się mniejszymi błędami w modelowaniu z użyciem PROSAIL. Odwrotne zależności występują w większości przedziałów spektrum w odniesieniu do zawartości wody: mniejsze błędy są w klasach o mniejszej zawartości wody. Stwierdzono, że w przypadku większych wartości wskaźnika powierzchni projekcyjnej liści (LAI) modelowanie jest skuteczniejsze w zakresie podczerwieni.

## Podsumowanie wyników

### Summary of the results

W ostatniej części rozdziału przedstawione zostanie porównanie skuteczności modeli PROSPECT i PROSAIL, a następnie ogólne podsumowanie.

Na podstawie przeprowadzonych badań stwierdzono, że łączny uśredniony pierwiastek błędu średniokwadratowego w zakresie widma od 0,4 do 2,5  $\mu\text{m}$ , obliczony na podstawie PROSAIL w stosunku do pomiarów terenowych wyniósł 0,1058, czyli był o 0,0068 większy niż w przypadku PROSPECT, gdzie wyniósł 0,099 (tab. 22.). W zakresach podczerwieni (0,8-1,5 i 1,5-2,5  $\mu\text{m}$ ) lepsze wyniki modelowania uzyskano z użyciem modelu PROSPECT niż PROSAIL. W zakresach promieniowania 0,4-0,6 i 0,4-0,8  $\mu\text{m}$  bardziej skuteczny był model na poziomie pokrywy roślinnej PROSAIL.

Tab. 22. Średnie wartości pierwiastków błędu średniokwadratowego obliczone między krzywymi odbicia spektralnego modelowanymi algorytmem PROSPECT i PROSAIL i uzyskanymi z pomiarów terenowych. W tabeli zaznaczono na szaro, w przypadku którego modelu otrzymano lepsze wyniki.

Tab. 22. The Root Mean Square Error values calculated using data from field measurements and PROSPECT and PROSAIL modelling. The grey coloured cells of the table indicates better results

Model Model	Zakres w $\mu\text{m}$ Wavelength in $\mu\text{m}$				
	0,4-2,5	0,4-0,6	0,4-0,8	0,8-1,5	1,5-2,5
PROSPECT	0,0990	0,0287	0,0398	0,0964	0,1151
PROSAIL	0,1058	0,0253	0,0376	0,1072	0,1230

Bardzo zbliżone relacje między wielkościami błędów uzyskano w przypadku modelowania PROSPECT i PROSAIL w podziale łąk na rodzaje: uprawiane o dużej biomase, uprawiane o zredukowanej biomase i nieuprawiane.

Porównano różnice w skuteczności modelowania z użyciem PROSPECT i PROSAIL w zależności od wartości LAI, zawartości biomasy świeżej i wody. W przypadku wszystkich trzech parametrów różnice w skuteczności modelowania obu modeli były dość podobne, szczególnie w zakresach 0,8-1,5 i 1,5-2,5  $\mu\text{m}$ . Rozbieżności między modelami były widoczne przy porównywaniu istotności statystycznej różnic w wielkości błędów. W przypadku trzech kategorii wartości LAI różnice istotne statystycznie stwierdzono w przypadku modelu PROSAIL. Ilość biomasy świeżej bardziej wpływała na skuteczność modelowania z użyciem PROSAIL niż PROSPECT. Zawartość wody miała równe znaczenie w skuteczności symulacji odbicia w obu modelach. Generalnie, skuteczność modelowania z użyciem PROSAIL bardziej zależała od zawartości parametrów biofizycznych niż miało to miejsce w przypadku PROSPECT.

Porównując modelowanie wykonane na poziomie liści i na poziomie pokrywy roślinnej z wykorzystaniem dwóch modeli, można stwierdzić, że w całym zakresie

widma od 0,4 do 2,5  $\mu\text{m}$  lepsze wyniki uzyskuje się z użyciem modelu PROSPECT.

Wartości pierwiastka błędu średniokwadratowego w symulacjach wykonywanych z użyciem PROSPECT i PROSAIL wzrastają wraz z długością fali. Największe błędy występują w zakresie środkowej podczerwieni (1,5-2,5  $\mu\text{m}$ ), w której duży wpływ na wartość współczynnika odbicia ma zawartość wody w roślinach. Wartości błędów w modelowaniu w tym zakresie są największe. Mniejsze wartości błędu uzyskiwane są w zakresie bliskiej podczerwieni (0,8-1,5  $\mu\text{m}$ ), w której dominujący wpływ na wartość odbicia promieniowania wywiera ilość biomasy suchej. Znacznie mniejsze błędy w porównaniu z zakresem podczerwonym występują w zakresach 0,4-0,6  $\mu\text{m}$  i 0,4-0,8  $\mu\text{m}$ . Najlepszą dokładność modelowania określa się w zakresie 0,4-0,6  $\mu\text{m}$ .

Badając założenia modeli stwierdzono, że wpływ na skuteczność modelowania mają rodzaj łąki i wartości parametrów biofizycznych.

W zakresach 0,4-0,6 i 0,4-0,8  $\mu\text{m}$  niezależnie od rodzaju łąki uzyskano zbliżone uśrednione wartości pierwiastka błędu średniokwadratowego. W zakresie podczerwieni (0,8-2,5  $\mu\text{m}$ ) najmniejsze błędy występują w charakterystykach spektralnych na terenie łąk nieuprawianych, a największe na obszarach łąk uprawianych o zredukowanej biomase. Jedynie w modelowaniu z użyciem algorytmu PROSAIL w zakresie środkowej podczerwieni (1,5-2,5  $\mu\text{m}$ ) różnice były istotne statystycznie. Stwierdzono, że rodzaj środowiska ma niewielki wpływ na rezultaty modelowania.

Poprawność modelowania zależy także od wartości parametrów biofizycznych. Niezależnie od modelu stwierdzono tę samą zależność dotyczącą biomasy świeżej. W przypadku klas łąk o jej większej zawartości błąd jest mniejszy. Wspomniane różnice w wielkościach błędów są istotne statystycznie w całym modelowanym zakresie 0,4-2,5  $\mu\text{m}$  i w podczerwieni 0,8-2,5  $\mu\text{m}$ . W zakresie podczerwieni (0,8-2,5  $\mu\text{m}$ ) mniejsze błędy występują na terenie łąk o większej wartości wskaźnika powierzchni projekcyjnej liści (LAI), ale różnice są istotne statystycznie tylko w przypadku modelowania według algorytmu PROSAIL.

Zbliżone tendencje przy stosowaniu obu modeli stwierdza się, badając wpływ zawartości wody w roślinach na skuteczność modelowania. Im większa jest zawartość wody, tym większa wartość błędu, a tym samym ograniczona skuteczność modelowania. Także i w tym przypadku, w obu modelach, w całym zakresie widma 0,4-2,5  $\mu\text{m}$  i w podczerwieni (0,8-2,5  $\mu\text{m}$ ), różnice są istotne statystycznie.

W zakresie widma widzialnego nie stwierdzono w przypadku żadnego z badanych parametrów istotnych statystycznie różnic.

Na podstawie przeprowadzonych badań można stwierdzić, że środowisko ma niewielki wpływ na skuteczność tego modelowania odbicia spektralnego z wykorzystaniem obu algorytmów. Jednocześnie poprawność modelowania zdecydowanie zależy od wartości parametrów biofizycznych roślinności.

## Dyskusja wyników Discussion and Conclusion

Celem zaprezentowanych badań było określenie możliwości zastosowania modeli transferu promieniowania – PROSPECT i PROSAIL w badaniach stanu zróżnicowanej roślinności łąkowej na terenie Polski. W badaniach były sprawdzone dwa modele transferu promieniowania służące do modelowania odbicia od pojedynczych liści (PROSPECT) i pokrywy roślinnej (PROSAIL) pod kątem poprawności obliczania współczynnika odbicia spektralnego. Określono, jakie czynniki wpływają na skuteczność symulacji charakterystyk spektralnych – badano zarówno morfologię roślinności, jak i zawartość substancji biofizycznych.

Modele transferu promieniowania na podstawie praw fizycznych określają, co dzieje się z promieniowaniem w atmosferze i w kontakcie z pokrywą roślinną. Modele te z konieczności opisują roślinność w sposób uproszczony. W Polsce modeli transferu promieniowania dotychczas nie używano do badań roślinności. W niniejszych badaniach zastosowano dwa modele: PROSPECT i PROSAIL (Jacquemoud, Baret, 1990; Jacquemoud, Ustin, Verdebout, Schmuck, Anderoli, Hosgood, 1996; Verhoef, 1984; 1985; Jacquemoud, Verhoef, Baret, Bacour, Zarco-Tejada, Asner, François, Ustin, 2009). W modelach zakłada się, że roślinność (liście, a także pokrywa roślinna) są jednorodne. Część z założeń zaprezentowanych w opisach modeli nie była spełniona w przypadku zbiorowisk trawiastych w przeprowadzonych badaniach.

Przedmiotem badań były łąki na terenie Polski. Ze względu na duże zróżnicowanie roślinności łąk są one trudne do modelowania, ponieważ na tych terenach występuje zawsze więcej niż jeden gatunek roślinności. Dominującymi gatunkami są na ogół trawy, które mają dosyć prostą i podobną budowę, na terenie badanych łąk jednak często występowały również rośliny o innej budowie niż gatunki wiechlinowate. Wśród nich znajdowały się rośliny kwitnące, rośliny motylkowe i zioła, które na terenie łąk występowały w sposób zróżnicowany przestrzennie, co sprawiało, że powierzchnie tych łąk były niejednorodne.

W pracy zbadano 57 łąk na terenie Pogórza Karpackiego i Równin Środkowopolskich, różniących się morfologią, strukturą i składem gatunkowym. Opisywane łąki należały do zbiorowisk półnaturalnych świeżych i w większości były ekstensywnie użytkowane. Na obszarze tylko ośmiu poligonów znajdowały się łąki porośnięte wyłącznie gatunkami wiechlinowatymi. Na terenie 23 łąk występowały rośliny motylkowe, które bardzo znacząco różnią się od traw. Do tej pory, jeśli badano zbiorowiska trawiaste, analizowano raczej łąki z obszarów suchych (Darvishzadeh, Skidmore, Schlerf, Atzberger, 2008; Darvishzadeh, Atzberger, Skidmore, Schlerf, 2011) lub łąki uprawiane o bardziej jednolitej strukturze (Clevers, Kooistra, Schaepman, 2010).

Różne gatunki roślin mają inną wartość parametrów biofizycznych – barwników, masy suchej i wody, które

stanowią zarazem dane wejściowe do modeli. Ujednoczenie wartości wymienionych substancji jest bardzo skomplikowane, a nawet niewielkie niedoszacowanie lub przeszacowanie tych parametrów może wpływać negatywnie na skuteczność modelowania. Zawartość wspomnianych substancji jest różna także w obrębie jednej rośliny, jednak większa różnica w wartościach parametrów występuje między różnymi gatunkami roślin. Jeszcze większe trudności z dobraniem odpowiedniej wartości pojawiają się w przypadku parametru zawartości brązowych pigmentów.

Tak duże zróżnicowanie gatunków roślin wpływa także na różną strukturę roślinności. W przypadku modelu PROSPECT tylko jeden parametr jest odpowiedzialny za modelowanie morfologii liści – parametr strukturalny. Jego wartości według założeń twórców modelu są zróżnicowane w przypadku różnych gatunków, dlatego ustalenie jednej wspólnej wartości jest skomplikowane (Jacquemoud, Ustin, Verdebout, Schmuck, Anderoli, Hosgood, 1996).

W modelu PROSAIL opisującym pokrywę roślinną, są uwzględnione parametry określające morfologię całej pokrywy roślinnej. Wartość parametru powierzchni projekcyjnej liści (LAI) na obszarze niejednorodnym musi być uśredniona w odniesieniu do całej badanej łąki, bez uwzględnienia jej zróżnicowania. Jeśli na jej terenie występują inne rośliny niż trawy, bardzo zwiększa się wartość biomasy, a tym samym parametru LAI. Rośliny motylkowe i zioła były rozmieszczone nierównomiernie na terenie badanych łąk, co utrudniało prawidłowe określenie parametru. Podobny problem występował w przypadku oszacowywania średniego kąta nachylenia liści (*angl*). Trawy mają bardzo dużą wartość nachylenia liści – około 80-90°, koniczyna natomiast niewielką (około 30°). Także parametr określający efekt nadmiernego odbicia *hot spot* (*hspot*) bazował na parametrach roślinności mierzonych w terenie, np. wysokości pokrywy roślinnej i średniej długości liści. Tymczasem roślinność, która nie jest jednorodna gatunkowo, na ogół ma różną wysokość i długość liści.

Czynnikiem utrudniającym modelowanie na terenach łąk o rzadkiej roślinności jest odbicie fal od gleby. Odbicie promieniowania od gleby może w znaczący sposób wpłynąć na wartości współczynnika odbicia od takiej zróżnicowanej powierzchni.

Wszystkie wymienione czynniki sprawiają, że modelowanie odbicia od roślinności takiej jak łąki jest dość trudne. Możliwe jest uwzględnianie czynników, które występują regularnie, np. jeśli rośliny sadzone są w rzędach. W przypadku roślinności o charakterze naturalnym lub półnaturalnym nie można przewidzieć rozmieszczenia poszczególnych gatunków, a tym samym wartości zmiennych biofizycznych i parametrów określających budowę pokrywy roślinnej. Z tych powodów uogólnianie tego typu środowisk jest skomplikowane i może być niedokładne.

W celu oceny skuteczności modelowania odbicia promieniowania z użyciem modeli transferu promieniowania w odniesieniu do rodzajów łąk, podzielono je



na trzy kategorie: uprawiane o zredukowanej biomase, uprawiane o dużej biomase i łąki nieuprawiane. Na terenie łąk uprawianych o zredukowanej biomase rośliny zostały skoszone, czyli ujednociono strukturę roślinności, a przede wszystkim jej wysokość. Roślinność nie zawsze była na nich tak gęsta, żeby zakryć w całości glebę, a prześwitywanie tła mogło negatywnie wpływać na skuteczność modelowania. Druga grupa obejmuje łąki o znacznie większej, niż poprzednie, biomase, a jednocześnie o zróżnicowanej wysokości. Najbardziej niejednorodną grupą były łąki nieuprawiane, o zmiennej wysokości i często dużej biomase.

Można stwierdzić, że badane łąki były obiektami dość skomplikowanymi przyrodniczo i dlatego trudne jest proste symulowanie odbijanego przez nie promieniowania przy użyciu obydwu modeli. Z tego właśnie powodu łąki są środowiskiem rzadko badanym z użyciem modeli transferu promieniowania. W niniejszych badaniach uwzględniono jak najwięcej zróżnicowanych terenów, aby określić, w jakim przypadku modelowanie jest skuteczne, a w jakim nie.

W modelowaniu odbicia promieniowania od roślin na poziomie pojedynczych liści wykorzystano model PROSPECT-5 (Jacquemoud, Baret, 1990; Jacquemoud, Ustin, Verdebout, Schmuck, Anderoli, Hosgood, 1996), a na poziomie pokrywy roślinnej PROSAIL, składający się z PROSPECT-5 i 4SAIL (Verhoef, 1984; 1985). Modele testowano na 57 poligonach. Obliczono wielkość średniego błędu modelowania w zależności od rodzaju łąk oraz od ilości biomasy świeżej, wartości parametru LAI oraz procentowej zawartości wody.

Na podstawie przeprowadzonych analiz stwierdzono, że modele PROSPECT i PROSAIL mogą być używane do modelowania odbicia od zróżnicowaniach zbiorowisk trawiastych, jednak z pewnymi ograniczeniami. Uzyskano dość duże rozbieżności między wartościami modelowanymi i zmierzonymi w terenie, szczególnie w zakresie podczerwieni. Wielkość błędu wzrasta wraz z długością fali: najmniejsze błędy występują w zakresie widzialnym, a największe w środkowej podczerwieni. Oznacza to, że najmniej dokładne modelowanie jest w środkowej podczerwieni.

Prawdopodobnie błędy w zakresie podczerwieni są spowodowane niedoszacowaniem zawartości wody. Błędy w zakresie widzialnym, chociaż zdecydowanie mniejsze, mogą mieć natomiast związek ze źle obliczoną zawartością chlorofilu. W przypadku zawartości chlorofilu błędy mogą być związane z urządzeniem pomiarowym. Ponadto zawartość chlorofilu jest bardzo zmienna w zależności od rośliny, a także w jej obrębie, co może prowadzić do zafalszowania rzeczywistej zawartości tego barwnika. Zawartość wody była szacowana na podstawie pomiarów reprezentatywnych. Ze względu na duże zróżnicowanie wewnętrzne w obrębie łąk, taka metoda określania zawartości wody w roślinach mogła jednak generować niejednoznaczne wartości tego parametru.

Oceniono również skuteczność modelowania odbicia spektralnego za pomocą obu modeli w zależności

od rodzaju łąki. Różnice obserwowane są w zakresie podczerwieni. Najmniejsze błędy w modelowanych charakterystykach spektralnych stwierdza się w zakresie promieniowania podczerwonego na terenie łąk nieuprawianych, a największe na obszarach łąk uprawianych o zredukowanej biomase. Różnice między poszczególnymi rodzajami łąk, choć widoczne, nie są jednak istotne statystycznie. Można wyciągnąć wniosek, że środowisko ma niewielki wpływ na skuteczność modelowania współczynnika odbicia. Pomimo niespełnienia założenia modeli o jednorodności środowiska na części łąk, wyniki modelowania nie różnią się istotnie od siebie. Wszystkie badane łąki były niejednorodne, jednak łąki nieuprawiane miały najbardziej zróżnicowaną strukturę poziomą i pionową. Prawdopodobnie różnica między środowiskami tego typu jest tak mała, że nie ma istotnego wpływu na modelowanie odbicia.

Bardziej jednoznaczne zależności uzyskano w przypadku oceny wpływu zawartości poszczególnych parametrów biofizycznych na skuteczność modelowania. Lepsze wyniki na podstawie danych wejściowych niemodyfikowanych, z zastosowaniem obu modeli, uzyskuje się w odniesieniu do roślinności łąk o większej biomase i większym wskaźniku powierzchni projekcyjnej liści (LAI) oraz mniejszej zawartości wody. Różnice są istotne statystycznie w podczerwieni oraz w całym modelowanym zakresie widma 0,4-2,5  $\mu\text{m}$ .

Na łąkach o niewielkiej ilości biomasy i wartości LAI duży wpływ na wielkość odbicia może mieć gleba, która jest widoczna między roślinami. Wartości odbicia są wtedy zmienione i różnią się od odbicia od samej roślinności. Prawdopodobnie także zwarta, gęsta pokrywa roślinna jest bardziej jednorodna niż rzadka. Zwarta masa roślin jest łatwiejsza do uogólnienia niż roślinność rzadka, gdzie promieniowanie jest wielokrotnie odbijane wewnątrz pokrywy.

W przypadku roślinności o większej zawartości wody uzyskuje się gorsze rezultaty symulacji krzywych odbicia spektralnego. Może to być związane z nieprawidłowym określeniem parametru zawartości wody. Ponadto model PROSPECT, w którym wśród danych wejściowych jest zawartość wody, jest dostosowany do standardowej pokrywy roślinności, także do zbóż. Łąki natomiast na ogół są zbiorowiskami bardzo wilgotnymi. Dlatego duża zawartość wody może powodować błędy w modelowaniu.

Można stwierdzić, że skuteczność modelowania zdecydowanie bardziej zależy od wielkości parametrów biofizycznych roślinności niż od rodzaju samego środowiska.

Porównując modelowanie PROSPECT i PROSAIL, nie stwierdza się dużych różnic między modelem opisującym promieniowanie na poziomie liści i pokrywy roślinnej. Na ogół nieco większe błędy występują w modelowaniu z użyciem modelu PROSAIL. W zakresie widzialnym lepsze rezultaty uzyskuje się z użyciem PROSAIL, a w bliskiej podczerwieni z modelem PROSPECT.

Modelowanie odbicia promieniowania od liści, w porównaniu z modelowaniem odbicia od pokrywy roślinnej, jest znacznie prostszym procesem, ponieważ w tym przypadku należy wziąć pod uwagę mniej czynni-

ków. Są tu uwzględniane jedynie parametry biofizyczne liści i parametr strukturalny określający złożoność struktury wewnętrznej liścia. Na współczynnik odbicia modelowany na poziomie pokrywy roślinnej wpływa natomiast znacznie więcej elementów. Konieczne jest uwzględnienie nie tylko samych liści, ale także ich rozmieszczenia, ilości, a także geometrii odbicia. Duży wpływ ma także odbicie promieniowania od gleby. Te wszystkie czynniki sprawiają, że modelowanie jest bardziej skomplikowane. Modele opisujące pojedyncze liście mogą być jednak stosowane jedynie w przypadku naziemnych pomiarów spektrometrycznych, co uniemożliwia ich dalsze wykorzystanie w badaniach na pułapie lotniczym lub satelitarnym. Tym samym jedynie modele określające promieniowanie na poziomie pokrywy roślinnej uwzględniające geometrię odbicia i strukturę pokrywy roślinnej mogą być używane do przetworzeń obrazów hiperspektralnych pobranych z pułapu lotniczego lub satelitarnego. Pomimo nieco gorszych rezultatów z użyciem modelu PROSAIL można stwierdzić, że ze względu na większą złożoność modelowania odbicia od pokrywy roślinnej, w porównaniu z odbiciem od pojedynczych liści, różnica w skuteczności modeli nie jest istotna.

Otrzymane z modeli krzywe odbicia spektralnego miały zbyt duże błędy, żeby mogły być użyte do przeprowadzania inwersji. Jedynie w zakresie widzialnym możliwe jest przeprowadzanie tego przekształcenia. Duże błędy w zakresie podczerwieni bardzo ograniczają możliwości obliczenia parametrów. Możliwa jest jednak poprawa uzyskanych wyników.

Uzyskane wyniki porównano z badaniami innych autorów. Przy zestawieniu wartości odbicia modelowanych i uzyskanych ze skanera MODIS jako maksymalną wartość pierwiastka błędu średniokwadratowego (RMSE), oznaczającą prawidłowe modelowanie przyjmowano 0,02 (Zhang, Zhao, 2009). W niniejszych badaniach wartości błędu były znacznie większe. Autorzy N. Zhang i Y. Zhao (2009) porównywali jedynie 7 kanałów spektralnych, natomiast w przeprowadzonych badaniach analizowano dane hiperspektralne. Ten sam próg błędu 0,02 zastosowano w badaniach zbiorowisk trawiastych na terenie Włoch, stwierdzając, że modelowane charakterystyki spektralne są przydatne do procesu inwersji (Darvishzadeh, Atzberger, Skidmore, Schlerf, 2011).

W czasie modelowania największym problemem było ustalenie odpowiednich wartości parametrów wejściowych do modeli. Wszystkie dane, z wyjątkiem parametru strukturalnego, były obliczone na podstawie pomiarów terenowych, błędy jednak były dość duże, co uniemożliwia dalszą analizę krzywych w całym zakresie, a także przeprowadzanie inwersji. Błędy mają prawdopodobnie związek z niewłaściwymi wartościami parametrów określających zawartość wody, a także chlorofilu. Może to być związane z niedokładnym wykonaniem pomiarów lub z dużym zróżnicowaniem badanego środowiska, co zostało wyjaśnione. Dlatego do dalszych analiz konieczne byłoby wprowadzenie korekcji danych wejściowych,

szczególnie parametrów określających barwniki i zawartość wody. Taka procedura była także stosowana w innych badaniach PROSPECT (Ceccato, Flasse, Tarantola, Jacquemoud, Grégoire, 2001; Zarco-Tejada, Miller, Harron, Hu, Noland, Goel, Mohammed, Sampson, 2004; le Maire, Francois, Dufrêne, 2004) i PROSAIL (Casa, Baret, Buis, Lopez-Lozano, Pascucci, Palombo, Jones, 2010; le Maire, Marsden, Verhoef, Ponzoni, Seen, Bégué, Stape, Nouvellon, 2011).

Największym problemem, w przypadku obu modeli, okazało się ustalenie wartości parametru strukturalnego  $N$ . Niemożliwe było ustalenie jednej wartości parametru dla wszystkich badanych łąk, dlatego ten parametr był określany oddzielnie w przypadku każdego poligonu. Co więcej, jedynie w przypadku modelu PROSPECT na poziomie pojedynczych liści parametr miał zakres zgodny z założeniami jego twórców (Jacquemoud, Ustin, Verdebout, Schmuck, Anderoli, Hosgood, 1996). W modelu PROSAIL zakres wartości był znacznie szerszy. Prawdopodobnie jest to związane ze znaczną złożonością środowiska łąk, jednak w innych badaniach, także obejmujących środowiska trawiaste, wartości parametru nie przekraczały 2 (Darvishzadeh, Skidmore, Schlerf, Atzberger, 2008), a w symulacji charakterystyk spektralnych dowolnych gatunków roślin wartości 6,65 (Bowyer, Danson, 2004). W przypadku większej liczby punktów pomiarowych dopasowywanie wartości staje się długotrwałą procedurą. Jeśli badania miałyby być zautomatyzowane, w przypadku większej liczby punktów konieczne byłoby opracowanie algorytmu odnajdującego optymalną wartość  $N$ .

Błędy występujące w modelowaniu mogą być związane ze znacznym zróżnicowaniem wewnętrznym łąkowych zbiorowisk roślinnych. Ten sam problem zauważono w badaniach zbiorowisk trawiastych na terenie Włoch. Badano skuteczność symulacji parametrów biofizycznych po przeprowadzeniu inwersji modelu (Darvishzadeh, Skidmore, Schlerf, Atzberger, 2008; Darvishzadeh, Atzberger, Skidmore, Schlerf, 2011). W symulacjach na wejściu były krzywe odbicia spektralnego, a danymi wyjściowymi – zmienne biofizyczne. W badaniach wykazano, że wyniki modelowania parametrów biofizycznych pogarszały się wraz ze wzrostem liczby występujących gatunków. Także na terenie wilgotnych łąk i pastwisk w Holandii zauważono większe błędy, jeśli środowisko było bardziej zróżnicowane (Clevers, Kooistra, Schaepman, 2010). Rozwiązaniem tego problemu mogłaby być modyfikacja modelu uwzględniająca poziomą niejednorodność pokrywy roślinnej.

Przeprowadzone badania pozwoliły w sposób obiektywny ocenić możliwości zastosowania modeli transferu promieniowania do badań roślinności. Do tej pory nie używano takich modeli do określania stanu roślinności na obszarze Polski. Modele takie są natomiast od lat używane poza granicami Polski, szczególnie do badań obszarów rolniczych – zbóż, roślin okopowych, plantacji, a także zbiorowisk naturalnych, takich jak lasy. Modele są bardzo przydatne ze względu na możliwość pozyski-

wania parametrów biofizycznych bezpośrednio z danych teledetekcyjnych. Z sukcesem stosowano je w określaniu zawartości chlorofilu czy wielkości biomasy. Mimo że środowiska, szczególnie naturalne i półnaturalne, takie jak łąki, są bardziej zróżnicowane niż dotychczas rozpatrywane obszary, to jednak wykorzystywanie modeli ułatwi monitorowanie terenów łąkowych, w tym pozyskiwanie informacji o wielkości biomasy.

Do tej pory modele niezwykle rzadko były używane do badań zróżnicowanych środowisk łąkowych. Modelem PROSAIL używano do badań wysokich traw prairii (Gao, Lesht, 1997), roślinności trawiastej z obszaru śródziemnomorskiego (Yerba, Chuvieco, Riaño, 2008; Darvishzadeh, Skidmore, Schlerf, Atzberger, 2008; Darvishzadeh, Atzberger, Skidmore, Schlerf, 2011), półsuchych stepów na obszarze Chin (Zhang, Zhao, 2009) oraz łąk zalewanych i pastwisk na obszarze Holandii (Clevers, Kooistra, Schaepman, 2010). Użycie algorytmu do badań na terenie naturalnych i półnaturalnych łąk można określić jako nowatorskie.

W wyniku wykonanych badań przetestowano oba modele na zróżnicowanych wewnętrznie oraz między sobą poligonach badawczych. W wykonanych badaniach wszystkie dane możliwe do pozyskania w terenie były obliczone z pomiarów terenowych. W ten sposób przeprowadzone badania pozwoliły na określenie rzeczywistej przydatności modeli do symulacji odbicia spektralnego od pokrywy roślinnej. W znacznej części badań z użyciem modeli transferu promieniowania wykorzystuje się jedynie podstawowe badania terenowe wykonywane w trakcie zobrazowania lub spektrometrycznych pomiarów naziemnych. Ze względu na trudności w pobieraniu dużej ilości danych nie wszystkie są mierzone w terenie, a część jest ustalana z góry. Dlatego użycie jednolitych danych pochodzących z badań terenowych prowadzi do bardziej wiarygodnej oceny skuteczności modelowania. Zastosowana procedura różniła się od badań dotychczas przeprowadzanych.

Najczęściej modele transferu promieniowania są stosowane do pozyskiwania parametrów. Bardzo rzadko natomiast przeprowadzane są badania, w których obiektywnie ocenia się możliwości stosowania modeli transferu promieniowania do modelowania odbicia od określonych środowisk oraz wskazują na ograniczenia używanych modeli.

Przeprowadzone badania są wiarygodne, możliwe jest jednak wystąpienie błędów w wartościach pomiarowych parametrów wejściowych do modelu, które są niedoszacowane. Dotyczy to zawartości w roślinach wody i chlorofilu. Ulepszenie określania zawartości chlorofilu można byłoby zrealizować przez zwiększenie liczby pomiarów wskaźnika zawartości chlorofilu (*Chlorophyll Content Index*). Można także zmienić metodykę pozyskiwania zawartości chlorofilu, na przykład poprzez pomiar jego zawartości metodą laboratoryjną (Siedlecka, Wróblewska, 2009). Pomiar zawartości wody mogłyby być wykonywane także na większej liczbie próbek pobieranych losowo lub przy użyciu większej ilości biomasy.

W przypadku zmienionego sposobu pozyskiwania wartości parametrów określających chlorofil i zawartość wody, badania byłyby jednak bardziej czasochłonne. Aby poprawić uzyskane wyniki konieczne jest wprowadzenie poprawek do danych wejściowych, szczególnie zawartości wody lub ewentualnie zmodyfikowanie modelu. Skorygowanie parametru określającego zawartość wody jest możliwe, ponieważ w przypadku prezentowanych badań istotne jest pozyskanie informacji o wielkości biomasy. Ponadto do dalszego udoskonalenia wyników modelowania odbicia promieniowania przydatne byłoby zautomatyzowanie procesu ustalania modyfikowanych parametrów wejściowych (zawartości barwników i wody w liściach), tak aby zmodyfikowane wartości optymalnych parametrów były generowane automatycznie. Podobny algorytm należałoby opracować w przypadku parametru strukturalnego  $N$ , który był dostosowywany.

Warto byłoby także wykonać badania na obszarze większej liczby poligonów oraz na bardziej zróżnicowanych typach łąk. W wykonanych badaniach nie wzięto pod uwagę pastwisk, które mają nieco inną budowę pokrywy roślinnej – jest ona niższa, o nierównej wysokości roślin, z częstymi prześwitami tła gleby oraz ze skupiskowym występowaniem roślin azotolubnych. Nie uwzględniono także zalewanych wilgotnych łąk, bogatych w turzycę, które mają inną budowę niż trawy.

Dalszym krokiem byłoby wykonanie inwersji modelu PROSAIL na podstawie opracowanych danych i otrzymanie wybranych zmiennych biofizycznych z charakterystyk spektralnych.

Można podjąć próbę poprawy skuteczności modelowania wartości odbicia, a także wykonania procedury inwersji modelu, korzystając z danych pozyskanych z pułapu lotniczego i satelitarnego. W ten sposób modelowanie mogłoby być wykonane na znacznie większym obszarze jednocześnie.

Na podstawie przeprowadzonych badań można stwierdzić, że modele transferu promieniowania mogą być przy modyfikacjach stosowane do symulowania współczynnika odbicia spektralnego w przypadku niejednorodnej roślinności trawiastej. Aby jednak było możliwe dalsze używanie modeli (np. w procesie inwersji do pozyskania zmiennych biofizycznych roślinności), konieczne byłoby wprowadzenie poprawek do danych wejściowych. Łąki są tak skomplikowanym środowiskiem, że niektóre z parametrów (zawartość barwników i zawartość wody) powinny być ustalone lub dopasowywane, a nie mierzone w terenie.

Na modelowanie znikomy wpływ ma rodzaj łąki i stopień jej złożoności. Na skuteczność symulacji współczynnika odbicia znacznie bardziej wpływają wartości poszczególnych parametrów biofizycznych. Lepsze rezultaty uzyskiwane są przy większej biomacie świeżej, większej powierzchni projekcyjnej liści i małej zawartości wody.

Przeprowadzone badania pozwalają na rzetelną ocenę możliwości zastosowania modeli transferu promieniowania do modelowania odbicia od złożonych środowisk roślinnych. Dzięki przeprowadzonym badaniom

było możliwe określenie czynników wpływających na skuteczność symulacji, a także wskazanie na ograniczenia, jakie mają modele. Zaprezentowane zostały możliwe rozwiązania napotkanych problemów. Badania stanowią dobrą podstawę do dalszych badań z użyciem modeli transferu promieniowania.

## Literatura

### References

- Abdul-Rahman A., Chen M., 2005, Spectral Volume Rendering based on the Kubelka-Munk Theory. *Eurographics*, vol. 24, nr 3.
- Andrieu B., Baret F., Jacquemoud S., Malthus T., Steven M., 1997, Evaluation of an Improved Version of SAIL Model for Simulating Bidirectional Reflectance of Sugar Beet Canopy. *Remote Sensing of Environment*, nr 40, str. 247-257.
- Aspinall R. J., 2002, Use of logistic regression for validation of maps of the spatial distribution of vegetation species derived from high spatial resolution hyperspectral remotely sensed data. *Ecological Modelling*, nr 157, str. 301-312.
- Atzberger C., 2004, Object-based retrieval of biophysical canopy variables using artificial neural nets and radiative transfer models. *Remote Sensing of Environment*, nr 93, str. 53-67.
- Bacour C., Jacquemoud S., Tourbier Y., Dechambre M., Frangi J.-P., 2002, Design and analysis of numerical experiments to compare four canopy reflectance models. *Remote Sensing of Environment*, nr 79, str. 72-83.
- Bałuch-Małecka A., Olszewska M., 2008, Produkcyjność przemiannych użytków zielonych w zależności od rodzaju mieszanki i poziomu nawożenia w warunkach Pojezierza Olsztyńskiego. *Łąkarstwo w Polsce*, nr 11, str. 9-14.
- Bański J., 2007, *Geografia rolnictwa Polski*. Polskie Wydawnictwo Ekonomiczne, Warszawa.
- Bartold M., 2008, Klasyfikacja drzewostanów na obrazie hiperspektralnym Hyperion (EO-1). *Teledetekcja Środowiska*, nr 39, str. 6-29.
- Blackburn G. A., Ferwerda J. G., 2008, Retrieval of chlorophyll concentration from leaf reflectance spectra using wavelet analysis. *Remote Sensing of Environment*, nr 112, str. 1614-1632.
- Bochenek Z., 1990, Wykorzystanie zdjęć satelitarnych AVHRR NOAA do określania stanu użytków zielonych. *Prace Instytutu Geodezji i Kartografii*, tom 27, zeszyt 1-2 (84-85), str. 49-61.
- Borawska-Jarmułowicz B., 2004, Wpływ 12-letniego użytkowania na trwałość gatunków i odmian traw w mieszankach łąkowych zróżnicowanych wczesnością. *Annales Universitatis Mariae Curie-Skłodowska Lublin – Polonia*. vol. 59, nr. 3, sectio E., str. 1397-1406.
- Bowyer P., Danson F. M., 2004, Sensivity of spectral reflectance to variation in live fuel moisture content at leaf and canopy level. *Remote Sensing of Environment*, nr 92., str. 297-308.
- Budzyńska M., Dąbrowska-Zielińska K., Turlej K., Małek I., Bartold M., 2011, Monitoring przyrodniczy Bagien Biebrzańskich z zastosowaniem teledetekcji. *Woda-Środowisko-Obszary Wiejskie*, t. 11, z. 3, str. 39-64.
- Burs W., Jankowska-Huflejt H., Wróbel B., Zastawny J., 2004, *Użytkowanie kośne użytków zielonych. Materiały dla rolników*. Krajowe Centrum Rolnictwa Ekologicznego – Regionalne Centrum Doradztwa Rozwoju Rolnictwa i Obszarów Wiejskich w Radomiu, Radom.
- Burzyńska I., 2009, Wpływ zaniechania nawożenia oraz zbioru runi łąkowej na zawartość RWO oraz rozpuszczalnych form potasu i magnezu w glebie i płytkich wodach gruntowych. *Woda – Środowisko – Obszary Wiejskie*, t. 9, z. 3 (27), str. 19-28.
- Carli B., 2006, *Basics about radiative transfer, Dragon advanced training course in atmosphere remote sensing*. [http://earth.eo.esa.int/dragon/D2\\_L2\\_Carli.pdf](http://earth.eo.esa.int/dragon/D2_L2_Carli.pdf).
- Casa R., Baret F., Buis S., Lopez-Lozano R., Pascucci S., Palombo A., Jones H. G., 2010, Estimation of maize canopy properties from remote sensing by inversion of 1-D and 4-D models. *Precision Agriculture*, nr 11, str. 319-334.
- Ceccato P., Flasse S., Tarantola S., Jacquemoud S., Grégorie J.-M., 2001, Detecting vegetation leaf water content using reflectance on the optical domain. *Remote Sensing of Environment*, nr 77, str. 22-33.
- Ciołkosz A., Dąbrowska-Zielińska K., 1993, Zastosowanie zdjęć satelitarnych do szacowania wielkości produkcji z trwałych użytków zielonych w Polsce. *Fotointerpretacja w geografii*, nr 23, str. 53-67.
- Clevers J. G. P. W., Kooistra L., Schaepman M. E., 2010, Estimating canopy water content using hyperspectral remote sensing data. *International Journal of Applied Earth Observation and Geoinformation*, nr 12, str. 119-125.
- Combal B., Baret F., Weiss M., Trubuil A., Macé D., Pragnère A., Myneni R., Knyazikhin Y., Wang L., 2002, Retrieval of canopy biophysical variables from bidirectional reflectance Using prior information to solve the ill-posed inverse problem. *Remote Sensing of Environment*, nr 84, str. 1-15.
- Dąbrowska-Zielińska K., Budzyńska M., Lewiński S., Hościło A., Bojanowski J., 2009, Application of remote and in situ information to the management of wetlands in Poland. *Journal of Environmental Management*, nr 90, str. 2261–2269.
- Dąbrowska-Zielińska K., Kowalik W., Gruszczyńska M., Hościło A., 2003, Wskaźniki roślinne dla obszaru bagien Biebrzańskich wyprowadzone ze zdjęć satelitarnych. *Archiwum Fotogrametrii, Kartografii i Teledetekcji*, nr. 13B, str. 349-359.
- Damarez V., Gastellu-Etchegorry J. P., 2000, A modeling approach for studying forest chlorophyll content. *Remote Sensing of Environment*, nr 71, str. 226-238.
- Darvishzadeh R., Atzberger C., Skidmore A., Schlerf M., 2011, Mapping grassland leaf area index with airborne hyperspectral imagery: A comparison study of statistical approaches and inversion of radiative transfer models. *ISPRS Journal of Photogrammetry and Remote Sensing*, nr 66 (6), str. 894-906.
- Darvishzadeh R., Skidmore A., Atzberger C., van Wieren S., 2008, Estimation of vegetation LAI from hyperspectral term reflectance data: Effects of soil type and plant architecture. *International Journal of Applied Earth Observation and Geoinformation*, nr 10 (3), str. 358-373.
- Darvishzadeh R., Skidmore A., Schlerf M., Atzberger C., 2008, Inversion of a radiative transfer model for estimating vegetation LAI and chlorophyll in heterogeneous grassland. *Remote Sensing of Environment*, nr 112, str. 2592-2604.
- Dawson T. P., Curran P. J., Plummer S. E., 1999, LIBERTY — Modeling the Effects of Leaf Biochemical Concentration on Reflectance Spectra. *Remote Sensing of Environment*, nr 65, str. 50-60.
- Dradrach A., Zdrojewski Z., 2008, Ocena produktywności runi łąkowej po podsiewie mieszanką jednoroczną (doniesienie naukowe). *Łąkarstwo w Polsce*, nr 11, str. 247-259.
- Duke C., Guérif M., 1998, Crop Reflectance Estimate Errors from the SAIL Model Due to Spatial and Temporal Variability of Canopy and Soil Characteristics. *Remote Sensing of Environment*, nr 66, str. 286-297.

- Duveiller G., Weiss M., Baret F., Defourny P., 2011, Retrieving wheat Green Area Index during the growing season from optical time series measurements based on neural network radiative transfer inversion. *Remote Sensing of Environment*, nr 115, str. 887–896.
- Fava F., Colombo R., Bocchi S., Meroni M., Sitzia M., Fois N., Zucca C., 2009, Identification of hyperspectral term vegetation indices for Mediterranean pasture characterization. *International Journal of Applied Earth Observation and Geoinformation*, nr 11 (4), str. 233-243.
- Feret J.-B., François C., Asner G. P., Gitelson A. A., Martin R. E., Bidel L. P. R., Ustin S., le Maire G., Jacquemoud S., 2008, PROSPECT-4 and 5: Advances in the leaf optical properties model separating photosynthetic pigments. *Remote Sensing of Environment*, nr 112, str. 3030-3043.
- Feret J.-B., François C., Gitelson A., Asner G. P., Barry K. M., Panigada C., Richardson A. D., Jacquemoud S., 2011, Optimizing spectral indices and chemometric analysis of leaf chemical properties using radiative transfer modeling. *Remote Sensing of Environment*, nr 115, str. 2742–2750.
- Fourty T., Baret F., Jacquemoud S., Schmuck G., Verdebout J., 1996, Leaf optical properties with explicit description of its biochemical composition: direct and inverse problems. *Remote Sensing of Environment*, nr 56, str. 104-117.
- Ganapol B. D., Johnson L. F., Hammer P. D., Hlavka C. A., Peterson D. L., 1998, LEAFMOD: A New Within-Leaf Radiative Transfer Model. *Remote Sensing of Environment*, nr 63, str. 182-193.
- Ganapol B. D., Johnson L. F., Hlavka C. A., Peterson D. L., Bond B., 1999, LCM2: A coupled Leaf/Canopy Radiative Transfer Model. *Remote Sensing of Environment*, nr 70, str. 153-166.
- Gao W., Lesht M., 1997, Model inversion of satellite-measured reflectances for obtaining surface biophysical and bidirectional reflectance characteristics of grassland. *Remote Sensing of Environment*, nr 59, str. 461-471.
- Gastellu-Etchegorry J. P., Zagolski F., Romier J., 1996, A Simple Anisotropic Reflectance Model for Homogeneous Multilayer Canopies. *Remote Sensing of Environment*, nr 57, str. 22-38.
- Goetz A. F. H., Vane G., Solomon J. E., Rock B. N., 1985, Imaging Spectrometry for Earth Remote Sensing. *Science*, vol. 228, nr 4704, str. 1147-1153.
- Grzegorzczak S., Grabowski K., 2010, Wpływ zaniechania rolniczego użytkowania zbiorowisk trawiastych obiektu Bezludy na zamiany w składzie gatunkowym. *Łąkarstwo w Polsce*, nr 13, str. 57-63.
- Haboudane D., Miller J. R., Pattey E., Zarco-Tejada P., Strachan I. B., 2004, Hyperspectral vegetation indices and novel algorithms for predicting green LAI for crop canopies: Modeling and validation in the context of precision agriculture. *Remote Sensing of Environment*, nr 90, str. 337-352.
- Haboudane D., Miller J. R., Tremblay N., Zarco-Tejada P., Dextraze L., 2002, Integrated narrow-band vegetation indices for prediction of crop chlorophyll content for application to precision agriculture. *Remote Sensing of Environment*, nr 81, str. 416-426.
- Hedley J., Roeslfsma C., Phinn S. R., 2009, Efficient radiative transfer model inversion for remote sensing applications. *Remote Sensing of Environment*, nr 113, str. 2527-2532.
- Hejmanowska B., 2007, Porównanie wyników klasyfikacji obrazów satelitarnych HYPERION i ALI. *Archiwum Fotogrametrii, Kartografii i Teledetekcji*, vol. 17a, str. 292-300.
- Houborg R., Anderson M., Daughtry C., 2009, Utility of an image-based canopy reflectance modeling tool for remote estimation of LAI and leaf chlorophyll content at the field scale. *Remote Sensing of Environment*, nr 113, str. 259–274.
- Houborg R., Soegaard H., Boegh E., 2007, Combining vegetation index and model inversion methods for the extraction of key vegetation biophysical parameters using Terra and Aqua MODIS reflectance data. *Remote Sensing of Environment*, nr. 106, str 39–58.
- Huemmerich K. F., 2001, The GeoSail model: a simple addition to the SAIL model to describe discontinuous canopy reflectance. *Remote Sensing of Environment*, nr 75, str. 423-431.
- Ishii J., Lu S., Funakoshi S., Shimizu Y., Omasa K., Washitani I., 2009, Mapping potential habitats of threatened plant species in a moist tall grassland using hyperspectral imagery. *Biodivers Conserv*, nr 18, str. 2521–2535.
- Jacquemoud S., 1993, Inversion of the PROSPECT+SAIL Canopy Reflectance Model from AVIRIS Equivalent Spectra: Theoretical Study. *Remote Sensing of Environment*, nr 44, str. 281-292.
- Jacquemoud S., Bacour C., Poilvé H., Frangi J. P., 2000, Comparison of Four Radiative Transfer Models to Simulate Plant Canopies Reflectance: Direct and Inverse Mode. *Remote Sensing of Environment*, nr 74, str. 471-481.
- Jacquemoud S., Baret F., 1990, PROSPECT: A Model of Leaf Optical Properties Spectra. *Remote Sensing of Environment*, nr 34, str. 75-91.
- Jacquemoud S., Baret F., Andrieu B., Danson F. M., Jaggard K., 1995, Extracting of vegetation biophysical parameters by inversion of the PROSPECT + SAIL models on sugar beet canopy reflectance data. Application to TM and AVIRIS sensors. *Remote Sensing of Environment*, nr 52, str. 163-172.
- Jacquemoud S., Baret F., Hanocq J. F., 1992, Modeling spectral and bidirectional soil reflectance. *Remote Sensing of Environment*, nr 41, str. 123-132.
- Jacquemoud S., Ustin S. L., Verdebout J., Schmuck G., Andeoli G., Hosgood B., 1996, Estimating Leaf Biochemistry Using the PROSPECT Leaf Optical Properties Model. *Remote Sensing of Environment*, nr 56, str. 194-202.
- Jacquemoud S., Verhoef W., Baret F., Bacour C., Zarco-Tejada P. J., Asner G. P., François H., Ustin S. L., 2009, PROSPECT+SAIL models: A review of use for vegetation characterization. *Remote Sensing of Environment*, nr 113, str. S56–S66.
- Jankowska-Huflejt H., Domański P. J., 2008, Aktualne i możliwe kierunki wykorzystania trwałych użytków zielonych w Polsce. *Woda-Środowisko-Obszary Wiejskie*, t. 8, z 2b, str. 31-49.
- Jarocińska A., Zagajewski B., 2008, Korelacje naziemnych i lotniczych teledetekcyjnych wskaźników roślinności dla zlewni Bystrzanki. *Teledetekcja Środowiska*, tom 40, str. 100-124.
- Jensen J. R., 1983, Biophysical Remote sensing – Review Article. *Annals of the Associations of American Geographers*, t. 73, nr 1, 111-132
- Kamiński J., 2004, Wpływ wykaszenia na zmiany w zbiorowisku łąki turzycowej zarastającej trzcina. *Woda – Środowisko – Obszary Wiejskie*, t. 4., z.1 (10), str. 241-246.
- Kamiński J., Chrzanowski S., 2009, Zróżnicowanie florystyczne i walory przyrodnicze łąk na tle zasobności gleb torfowo-murszowych w fosfor. *Woda – Środowisko – Obszary Wiejskie*, t. 9, z. 3 (27), str. 77-88.
- Kasperczyk M., Kacprzyk P., 2008, Wpływ rodzaju nawożenia na wartość gospodarczą łąki górskiej. *Woda – Środowisko – Obszary Wiejskie*, t. 8., z. 1 (22), str. 143-150.
- Kasperczyk M., Szewczyk W., 2006, Skuteczność wapnowania łąki górskiej. *Woda – Środowisko – Obszary Wiejskie*, t. 6, z. 1 (16), str. 153-159.
- Kawamura K., Watanabe N., Sakanoue S., Inoue Y., 2008, Estimating forage biomass and quality in a mixed sown

- pasture based on partial least squares regression with waveband selection. *Grassland Science*, nr 54, str. 131–145.
- Kim Y., Glenn D. M., Park J., Ngugi H. K., Lehman B. L., 2011, Hyperspectral image analysis for water stress detection of apple trees. *Computers and Electronics in Agriculture*, nr 77, str. 155–160.
- Kiryłuk A., 2008, Wpływ 20-letniego użytkowania łąk pobagiennych na zmianę niektórych właściwości fizyczno-wodnych gleb oraz kształtowanie się zbiorowisk roślinnych. *Woda – Środowisko – Obszary Wiejskie*, t. 8, z. 1 (22), str. 151-160.
- Kiteczak T., Czyż H., 2003, Wpływ użytkowania trwałych użytków zielonych na użytkowanie oraz skład florystyczny i chemiczny runi. *Acta Agrophysica*, nr 1, str. 109-114.
- Koetz B., Schaepman M., Morsdorf F., Bowyer P., Itten K., Allgöwer B., 2004, Radiative transfer modeling within a heterogeneous canopy for estimation of forest fire fuel properties. *Remote Sensing of Environment*, nr 92, str. 332–344.
- Koetz B., Baret F., Poilvé H., Hill J., 2005, Use of coupled canopy structure dynamic and Radiative transfer models to estimate biophysical canopy characteristics. *Remote Sensing of Environment*, nr 95, str. 115-124.
- Kosiński K., Hoffmann-Niedek A., 2008, Klasyfikacja obiektowa użytków zielonych z wykorzystaniem wieloletnich zmian NDVI i filtracji kierunkowych obrazu satelitarnego. *Archiwum Fotogrametrii, Kartografii i Teledetekcji*, Vol. 18, str. 273-281.
- Kosiński K., Kozłowska T., 2003, Zastosowanie wskaźnika NDVI i filtracji kierunkowej do rozpoznawania użytków zielonych oraz analizy zmian siedlisk i zbiorowisk łąkowych. *Archiwum Fotogrametrii, Kartografii i Teledetekcji*, Vol. 13 B, str. 387-395.
- Köts B., Schaepman M., Morsdorf F., Bowyer P., Itten K., Allgöwer B., 2004, Radiative transfer modeling within a heterogeneous canopy for estimation of forest fire fuel properties. *Remote Sensing of Environment*, nr 92, str. 332-344.
- Kozłowska T., Dąbrowska-Zielińska K., Ostrowski J., Ciołkosz A., Stankiewicz K., Bochenek Z., 2000, *Szacowanie plonów z użytków zielonych w skali regionalnej z zastosowaniem teledetekcji satelitarnej*. wyd. IMUZ, Falenty.
- Kozłowska T., Kosiński K., Kwiecień R., Ziaja W., 2004, Zastosowanie wskaźnika NDVI do wyróżniania łąk o różnym poziomie użytkowania i uwilgotnienia. *Woda – Środowisko – Obszary Wiejskie*, t. 4., z.1., str. 201-218.
- Kozłowska T., Rogowski W., Banaszek P., 1994, Ocena uwilgotnienia siedlisk łąkowych metodą tradycyjną oraz teledetekcji satelitarnej. *Fotointerpretacja w geografii*, nr 24, str. 62-67.
- Kryszak A., 2004, Syntantropizacja wybranych zbiorowisk łąkowych. *Woda – Środowisko – Obszary Wiejskie*, t. 4., z.1.(10), str. 201-208.
- Kucharski L., 2009, *Trwałe użytki zielone w programie rolno-środowiskowym*, Biblioteczka Programu Rolnośrodowiskowego 2007-2013. Ministerstwo Rolnictwa i Rozwoju Wsi, Warszawa.
- Kumar L., Schmidt K., Dury S., Skidmore A., 2006, Imaging spectrometry and vegetation science, W: van der Meer F. D., de Jong S. M. (red.) *Imaging Spectrometry. Basic principles and Prospective Applications*. wyd. Springer, Holandia, str. 111-155.
- Kuusik A., 1991, The angular-distribution of reflectance and vegetation indexes on barley and clover canopies. *Remote Sensing of Environment*, nr 37, str. 143-151.
- Kuusik A., 1994, A computer-efficient plant reflectance model. *Computers & Geosciences*, nr 22 (2), str. 194-163.
- Łabędzki L., 2003, Wpływ czynników meteorologicznych i roślinnych oraz wilgotności gleby na temperaturę radiacyjną roślin w różnych siedliskach łąkowych. *Woda – Środowisko – Obszary Wiejskie*, t. 3., z.1 (9), str. 99-112.
- le Maire G., François C., Soudani K., Berveiller D., Pontailleur J.-Y., Bréda N., Genet H., Davi H., Dufrêne E., 2008, Calibration and validation of hyperspectral indices for the estimation of broadleaved forest leaf chlorophyll content, leaf mass per area, leaf area index and leaf canopy biomass. *Remote Sensing of Environment*, nr 112, str. 3846–3864.
- le Maire G., Francois C., Dufrêne E., 2004, Towards universal broad leaf chlorophyll indices using PROSPECT simulated database and hyperspectral reflectance measurements. *Remote Sensing of Environment*, nr 89, str. 1-28.
- le Maire G., Marsden C., Verhoef W., Ponzoni F. J., Seen D. L., Bégué A., Stape J.-L., Nouvellon Y., 2011, Leaf area index estimation with MODIS reflectance time series and model inversion during full rotations of Eucalyptus plantations. *Remote Sensing of Environment*, nr 115, str. 586–599.
- Lewiński S., Gruszczyńska M., 1992, Badanie zależności między temperaturą radiacyjną mierzoną z pułapu lotniczego i satelitarnego a LAI, biomasa i wilgotnością gleby użytków zielonych. *Prace Instytutu Geodezji i Kartografii*, tom 39, zeszyt 1 (87), str. 127-133.
- Liu Y., Chen H., Wua G., Wua W., 2010, Feasibility of estimating heavy metal concentrations in Phragmites australis using laboratory-based hyperspectral data—A case study along Le'an River, China. *International Journal of Applied Earth Observation and Geoinformation*, nr 12S, str. S166–S170.
- Lucas K. L., Carter G. A., 2008, The use of hyperspectral remote sensing to assess vascular plant species richness on Horn Island, Mississippi. *Remote Sensing of Environment*, nr 112, str. 3908-3915.
- Meroni, M., Colombo R., Panigada C., 2004, Inversion of a radiative transfer model with hyperspectral observations for LAI mapping in poplar plantations. *Remote Sensing of Environment*, nr 92, str. 195-206.
- Miao X., Gong P., Swope S., Pu R., Carruthers R., Anderson G. L., Heaton J. S., Tracy C.R., 2006, Estimation of yellow star thistle abundance through CASI-2 hyperspectral imagery using linear spectral mixture models. *Remote Sensing of Environment*, nr 101, str. 329–341.
- Migdall S., Bach H., Bobert J., Wehrhan M., Mauser W., 2009, Inversion of a canopy reflectance model using hyperspectral imagery for monitoring wheat growth and estimating yield. *Precision Agriculture*, nr 10, str. 508-524.
- Muhammed H. H., Larsolle A., 2003, Feature Vector Based Analysis of Hyperspectral Crop Reflectance Data for Discrimination and Quantification of Fungal Disease Severity in Wheat. *Biosystems Engineering*, nr 86 (2), str. 125–134.
- Mutanga O., Skidmore A. K., 2004, Integrating imaging spectroscopy and neural networks to map grass quality in the Kruger National Park, South Africa. *Remote Sensing of Environment*, nr 90, str. 104– 115.
- Mutanga O., Skidmore A. K., van Wieren S., 2003, Discriminating tropical grass (*Cenchrus ciliaris*) canopies grown under different nitrogen treatments using spectroradiometry. *ISPRS Journal of Photogrammetry & Remote Sensing*, nr 57, str. 263– 272.
- Nadolna L., Paszkiewicz-Jasińska A., 2007, Plonowanie łąki górskiej Sudetach na podstawie wyników badań w świetle zmieniających się trendów nawożenia użytków zielonych. *Woda – Środowisko – Obszary Wiejskie*, t. 7, z. 2a (20), str. 257-270.
- Nawara Z., 2006, *Rośliny łąkowe*. wyd. MULTICO, Warszawa
- North P. R. J., 1996, Three-dimensional forest light interaction model using a Monte Carlo metod, *IEEE Transactions on Geoscience and Remote Sensing*, nr 34, str. 946–956.
- Nouvellon Y., Moran M. S., Seen D. L., Bryant R., Rambal S., Ni W., Bégué E., Chehbouni A., Emmerich W. E., Heilman

- P., Qi J., 2001, Coupling a grassland ecosystem model with Landsat imagery for a 10-year simulation of carbon and water budgets. *Remote Sensing of Environment*, nr 78, str. 131–149.
- Oleđzki J. R., 2007, *Regiony geograficzne Polski*. Teledetekcja Środowiska, nr 38, str. 1-337.
- Olesiuk D., Zagajewski B., 2008, Wykorzystanie obrazów hiperspektralnych do klasyfikacji pokrycia terenu zlewni Bystrzanki. *Teledetekcja środowiska*, tom 40, Str. 125-148.
- Olszewska M., Grzegorzczak S., Olszewski J., Bałuch-Malecka A., 2010, Porównanie reakcji wybranych gatunków traw na stres wodny. *Łąkarstwo w Polsce*, nr 13, str. 127-136.
- Osińska-Skotak K., 2009, Możliwości teledetekcyjnego monitorowania zawartości chlorofilu-a w wodach śródlądowych. *Teledetekcja Środowiska*, nr 42, str. 59-68.
- Piekarczyk J., Sulewska H., 2010, Assessment of winter spelt and wheat growth and yield by ground spectral measurements. *Acta Agrophysica*, nr 15 (2), str. 371-381.
- Prokopowicz J., Jankowska-Huflejt H., 2007, Wyniki ekonomiczno-rolnicze produkcji łąkarskich gospodarstw ekologicznych. *Woda – Środowisko – Obszary Wiejskie*, t. 7., z. 1 (19), str. 141-157.
- Prokopowicz J., Jurczyk S., 2008, Ocena ekonomiczna nawodnień podsiąkowych na łąkach położonych na glebach torfowo-murszowych. *Woda – Środowisko – Obszary Wiejskie*, t. 8., z. 1 (22), str. 247-261.
- Prokopowicz J., Kowalczyk J., 2007, Różnice w plonowaniu łąk i pastwisk na glebach torfowych w doświadczeniach łąkarskich i skali produkcyjnej. *Woda – Środowisko – Obszary Wiejskie*, t. 7., z. 1 (19), str. 159-170.
- Radkowski A., Kuboń M., 2006, Wpływ rodzaju koszenia na bioróżnorodność i wartość użytkową runi łąkowej. *Inżynieria Rolnicza*, nr 13, str. 403-408.
- Rahman A. F., Gamon J. A., 2004, Detecting biophysical properties of a semi-arid grassland and distinguishing burned from unburned areas with hyperspectral term reflectance. *Journal of Arid Environments*, nr 58 (4), str. 597-610.
- Richter R., Schlöpfer D., 2002, Geo-atmospheric processing of airborne spectrometry data. Part 2: atmospheric/topographic correction. *International Journal of Remote Sensing*, nr 23, str. 2631-2649.
- Schaepman M. E., Koetz B., Schaepman-Strub G., Itten K. I., 2005, Spectrodirectional remote sensing for the improved estimation of biophysical and -chemical variables: two case studies. *International Journal of Applied Earth Observation and Geoinformation*, nr 6, str. 271–282.
- Schmidtlein S., Sassini J., 2004, Mapping of continuous floristic gradients in grasslands using hyperspectral imagery. *Remote Sensing of Environment*, nr 92, str. 126-138.
- Schut A. G. T., Ketelaars J. J. M. H., Meuleman J., Kornet J. G., Lokhorst C., 2002, Novel Imaging Spectroscopy for Grass Sward Characterization. *Biosystems Engineering*, nr 82 (2), str. 131–141.
- Siedlecka M., Wróblewska B., 2009, 5.3. Fotosyntetyczne podstawy pomiarów biometrycznych. W: Oleđzki J. R. (red.) *Zintegrowane badania środowiska*, Uniwersytet Warszawski Wydział Geografii i Studiów Regionalnych, Warszawa.
- Smith M. L., Ollinger S. V., Martin M. E., Aber J. D., Hallett R. A., Goodale C. L., 2002, Direct estimation of above-ground forest productivity through hyperspectral remote sensing of canopy nitrogen. *Ecological Applications*, t. 12, nr. 5, 1286-1302.
- Sobczak M., Folbrier A., Kozłowska A., Krówczyńska M., Pabjanek P., Wrzesień M., Zagajewski B., 2005, Assessment of the potential of hyperspectral data and techniques for mountain vegetation analysis. *Imaging spectroscopy. New quality of Environmental Studies*, EARSeL i Uniwersytet Warszawski, Warszawa.
- Stypiński P., 2009, Zasady typologii i waloryzacji siedlisk łąkowych. [http://www.mppl.pl/obserwatorzy/Zasady%20typologii%20i%20waloryzacji%20siedlisk%20lakowych\\_Piotr%20Stypinski.pdf](http://www.mppl.pl/obserwatorzy/Zasady%20typologii%20i%20waloryzacji%20siedlisk%20lakowych_Piotr%20Stypinski.pdf).
- Suárez L., Zarco-Tejada P. J., Berni J. A. J., González-Dugo V., Fereres E., 2009, Modelling PRI for water stress detection using radiative transfer models. *Remote Sensing of Environment*, nr 113, str. 730-744.
- Suzuki Y., Tanaka K., Kato W., Okamoto H., Kataoka T., Shimada H., Sugiura T., Shima E., 2008, Field mapping of chemical composition of forage using hyperspectral imaging in a grass meadow. *Grassland Science*, nr 54, str. 179–188.
- Szweykowska A., Szweykowski J., 2008, *Botanika tom I. Morfologia*. Wydawnictwo Naukowe PWN, Warszawa.
- Tian Y. C., Yao X., Yang J., Cao W. X., Hannaway D. B., Zhu Y., 2011, Assessing newly developed and published vegetation indices for estimating rice leaf nitrogen concentration with ground- and space-based hyperspectral term reflectance. *Field Crops Research*, nr 120 (2), str. 299-310.
- Tomimatsu H., Itano S., 2009, Differences in spectrum reflectance and physiological indices among three typical seminatural grasslands in Japan. *Grassland Science*, nr 55, str. 221–224.
- Tretyn A., 2007, Podstawy strukturalno-funkcjonalne komórki roślinnej; W: Kopcewicz J., Lewak S. (red.), *Fizjologia roślin*, Wydawnictwo Naukowe PWN, Warszawa, str. 22-87.
- Underwood E. C., Mulitsch M. J., Greenberg J. A., Whiting M. L., Ustin S. L., Kefauver S. C., 2006, Mapping invasive aquatic vegetation in the Sacramento-San Joaquin delta using hyperspectral imagery. *Environmental Monitoring and Assessment*, nr 121, str. 47–64.
- Ustin S. L., Roberts D. A., Gamon J. A., Asner G. P., Green R. O., 2004, Using Imaging Spectroscopy to Study Ecosystem Processes and Properties. *Bioscience*, tom 54, nr 6., str. 523-533.
- Vaiphasa C., Ongsomwang S., Vaiphasa T., Skidmore A. K., 2005, Tropical mangrove species discrimination using hyperspectral data: A laboratory study, Estuarine. *Coastal and Shelf Science*, nr 65, str. 371-379.
- Verger A., Baret F., Camacho F., 2011, Optimal modalities for radiative transfer-neural network estimation of canopy biophysical characteristics: Evaluation over an agricultural area with CHRIS/PROBA observations. *Remote Sensing of Environment*, nr 115, str. 415–426
- Verhoef W., 2002, Improved modeling of multiple scattering in leaf canopies: The model SAIL++, W: J. A. Sobrino (red), *Proc. 1st Int. Symp. On Recent Advantages in Quantitative Remote Sensing*, Spain, Universitat dr Valencia, str. 11-20.
- Verhoef W., 1984, Light scattering by leaf layers with application to canopy reflectance modeling: The SAIL model. *Remote Sensing of Environment*, nr 16, str. 125-141.
- Verhoef W., 1985, Earth observation modeling based on layer scattering matrices. *Remote Sensing of Environment*, nr 17, str. 165-178.
- Verhoef W., Bach H., 2003, Simulation of hyperspectral and directional radiance images using coupled biophysical and atmospheric radiative transfer models. *Remote Sensing of Environment*, nr 87, str. 23-41
- Verhoef W., Bach H., 2007, Coupled soil–leaf–canopy and atmosphere radiative transfer modeling to simulate hyperspectral multi-angular surface reflectance and TOA radiance data. *Remote Sensing of Environment*, nr 109, str. 166–182.
- Verhoef W., Jia L., Xiao Q., Su Z., 2007, Unified Optical-Thermal Four-Stream Radiative Transfer Theory for Homogeneous Vegetation Canopies. *IEEE Transactions on Geoscience and Remote Sensing*, nr 45, str. 1808-1822.

- Verstraete M.M., Pinty B., 2001, Introduction to special section: modeling, measurement, and exploitation of anisotropy in the radiation field. *Journal of geophysical research – atmospheres*, nr 106, str. 11903–11907.
- Vohland M., Mader S., Dorigo W., 2010, Applying different inversion techniques to retrieve stand variables of summer barley with PROSPECT + SAIL. *International Journal of Applied Earth Observation and Geoinformation*, nr 12, str. 71-80.
- Weihls P., Suppan F., Richter K., Petritsch R., Hasenauer H., Schneider W., 2008, Validation of forward and inverse modes of a homogeneous canopy reflectance model. *International Journal of Remote Sensing*, nr 29 (5), str. 1317-1338.
- Weiss M., Baret F., Myneni R., Pragnère A., Knyazikhin Y., 2000, Investigation of a model inversion technique to estimate canopy biophysical variables from spectral and directional reflectance data. *Agronomie*, nr 20, str. 3-22.
- Weiss M., Troufleau D., Baret F., Chauki H., Prévot L., Olioso A., Bruguier N., Brisson N., 2001, Coupling canopy functioning and radiative transfer models for remote sensing data assimilation. *Agricultural and Forest Meteorology*, nr 108, str. 113–128.
- Wężyk P., Wertz B., Waloszek A., 2003, Skaner hiperspektralny AISA (Airborne Imaging Spectrometer for Applications) jako narzędzie pozyskiwania informacji o ekosystemie leśnym. *Archiwum Fotogrametrii, Kartografii i Teledetekcji*, vol. 13B., Materiały Ogólnopolskiego Sympozjum Geoinformacji „Geoinformacja zintegrowanym narzędziem badań przestrzennych”, Wrocław – Polanica Zdrój, 15-17 września 2003 r., str. 485-496.
- Yang C., Everitt J. H., Fernandez C. J., 2010, Comparison of airborne multispectral and hyperspectral imagery for mapping cotton root rot. *Biosystems Engineering*, nr 107, str. 131-139.
- Yao Y., Liu Q., Liu Q., Li X., 2008, LAI retrieval and uncertainty evaluations for typical row-planted crops at different growth stages. *Remote Sensing of Environment*, nr 112, str. 94-106
- Ye X., Sakai K., Okamoto H., Garciano L. O., 2008, A ground-based hyperspectral term imaging system for characterizing vegetation spectral features. *Computers and Electronics in Agriculture*, nr 63 (1), str. 13-21.
- Yerba M., Chuvieco E., Riaño D., 2008, Estimation of live fuel moisture content from MODIS images for fire risk assessment. *Agricultural and Forest Meteorology*, nr 148, str. 523-536.
- Zagajewski B., 2010, Ocena przydatności sieci neuronowych i danych hiperspektralnych do klasyfikacji roślinności Tatr Wysokich. *Teledetekcja środowiska*, tom 43, s. 1-113.
- Zagajewski B., Kozłowska A., Krówczyńska M., Sobczak M., Wrzesień M., 2005, Mapping high mountains vegetation Rusing hyperspectral data. *EARSel eProceedings*, nr 4 (1), str. 70-78.
- Zagajewski B., Lechnio J., Sobczak M., 2007, Wykorzystanie teledetekcji hiperspektralnej w analizie roślinności zanieczyszczonej metalami ciężkimi. *Teledetekcja Środowiska*, nr 37, str. 82-100.
- Zagajewski B., Sobczak M., Wrzesień M., 2004, Badania górskich zbiorowisk roślinnych z użyciem technik hiperspektralnych. *Przegląd Geofizyczny*, z. 3-4, str.115-129.
- Zarco-Tejada P.J., Miller J.R., Morales A., Berjón A., Agüera J., 2004, Hyperspectral indices and model simulation for chlorophyll estimation in open canopy-tree crops. *Remote Sensing of Environment*, nr 90, str. 462-476.
- Zarco-Tejada P. J., Miller J. R., Harron J., Hu B., Noland T. L., Goel N., Mohammed G. H., Sampson P., 2004, Needle chlorophyll content estimation through model inversion using hyperspectral data from boreal conifer forest canopies. *Remote Sensing of Environment*, nr 89, str. 189-199.
- Zarco-Tejada P. J., Rueda C. A., Ustin S. L., 2003, Water content estimation in vegetation with MODIS reflectance data and model inversion methods. *Remote Sensing of Environment*, nr 85, str. 109-124
- Zhang M., Qin Z., Liu X., Ustin S. L., 2003, Detection of stress in tomatoes induced by late blight disease in California, USA, using hyperspectral remote sensing. *International Journal of Applied Earth Observation and Geoinformation*, nr 4, str. 295–310.
- Zhang N. Zhao Y., 2009, Estimating leaf area index by inversion of reflectance model for semiarid natural grasslands. *Science in China Series D: Earth Sciences*, nr. 52 (1), str. 66-84.
- Zhao D., Starks P. J., Brown M. A., Phillips W. A., Coleman S. W., 2007, Assessment of forage biomass and quality parameters of bermudagrass using proximal sensing of pasture canopy reflectance. *Grassland Science*, nr 53, str. 39–49.
- Zwijacz-Kozica M., 2010, Zróżnicowanie kosodrzewiny w Tatrach, w świetle badań teledetekcyjnych. *Teledetekcja Środowiska*, str. 61

### Strony internetowe:

- CCM-200 plus, <http://www.optisci.com/ccm200.htm>
- Earth Observation and Satellite Imagery, [www.ga.gov.au/earth-observation/satellites-and-sensors/eo-1-satellite.html](http://www.ga.gov.au/earth-observation/satellites-and-sensors/eo-1-satellite.html)
- Environmental Mapping and Analysis Program, [www.enmap.org](http://www.enmap.org)
- PROSPECT+SAIL=PROSAIL, <http://teledetection.ipgp.jussieu.fr/prosail/>
- Sun or Moon Altitude/Azimuth Table: Locations Worldwide, <http://www.usno.navy.mil/USNO/astronomical-applications/data-services/alt-az-world>