



**INSTYTUT
AGROFIZYKI
P A N**



HR EXCELLENCE IN RESEARCH

AUTOREFERAT

załącznik 2A

dr Jaromir Radosław Krzyszczak

adiunkt

Zakład Metrologii i Modelowania Procesów Agrofizycznych

Instytut Agrofizyki im. Bohdana Dobrzańskiego Polskiej Akademii Nauk

ul. Doświadczalna 4

20-290 Lublin

e-mail: jkrzyszczak@ipan.lublin.pl

Lublin 2019

Spis treści

1. Dane personalne.....	3
2. Posiadane dyplomy, stopnie naukowe – z podaniem nazwy, miejsca i roku ich uzyskania oraz tytułu rozprawy doktorskiej.....	3
3. Informacje o dotychczasowym zatrudnieniu w jednostkach naukowych.....	3
4. Wskazanie osiągnięcia wynikającego z art. 16 ust. 2 ustawy z dnia 14 marca 2003 roku o stopniach naukowych i tytule naukowym oraz o stopniach i tytule w zakresie sztuki (Dz. U. 2016 r. poz. 882 ze zm. w Dz. U. z 2016 r. poz. 1311.).....	4
4.1 Tytuł osiągnięcia naukowego.....	4
4.2 Publikacje składające się na osiągnięcie naukowe.....	4
4.3 Omówienie celu naukowego ww. prac i osiągniętych wyników wraz z omówieniem ich ewentualnego wykorzystania.....	5
5. Omówienie pozostałych osiągnięć naukowo-badawczych.....	37
6. Podsumowanie dorobku naukowego.....	46

1. Dane personalne:

Jaromir Radosław Krzyszcak

Data urodzenia: **27.08.1982 r.**

2. Posiadane dyplomy, stopnie naukowe – z podaniem nazwy, miejsca i roku ich uzyskania oraz tytułu rozprawy doktorskiej:

- 2001-2006 Uniwersytet Marii Curie Skłodowskiej w Lublinie,
Wydział Matematyki, Fizyki i Informatyki,
magisterskie studia stacjonarne na kierunku fizyka,
specjalność fizyka teoretyczna.
Stopień **magistra** fizyki uzyskany 7.07.2006 r.
Praca magisterska pt. *Dynamika par Coopera w układach fermionów z oddziaływaniem zależnym od czasu.*
Promotor: prof. dr hab. Karol I. Wysokiński
Promotor pomocniczy: dr hab. Tadeusz Domański
- 2006-2011 Uniwersytet Marii Curie Skłodowskiej w Lublinie,
Wydział Matematyki, Fizyki i Informatyki,
studia doktoranckie na kierunku fizyka,
specjalność teoria ciała stałego.
Stopień **doktora** nauk fizycznych w dyscyplinie fizyki uzyskany
30.05.2011 r.
Rozprawa doktorska pt. *Teoretyczny opis niejednorodności w nadprzewodnikach.*
Promotor: prof. dr hab. Karol I. Wysokiński
Recenzenci: prof. dr hab. Ryszard Taranko, prof. dr hab. Marcin Mierzejewski

3. Informacje o dotychczasowym zatrudnieniu w jednostkach naukowych:

- 2012-2013 młodszy fizyk w Zakładzie Metrologii i Modelowania Procesów Agrofizycznych w Instytucie Agrofizyki im. Bohdana Dobrzańskiego Polskiej Akademii Nauk w Lublinie
- 2013-obecnie adiunkt w Zakładzie Metrologii i Modelowania Procesów Agrofizycznych w Instytucie Agrofizyki im. Bohdana Dobrzańskiego Polskiej Akademii Nauk w Lublinie

4. Wskazanie osiągnięcia wynikającego z art. 16 ust. 2 ustawy z dnia 14 marca 2003 roku o stopniach naukowych i tytule naukowym oraz o stopniach i tytule w zakresie sztuki (Dz. U. 2016 r. poz. 882 ze zm. w Dz. U. z 2016 r. poz. 1311.)

4.1. Tytuł osiągnięcia naukowego:

Osiągnięcie, będące podstawą do ubiegania się o stopień naukowy doktora habilitowanego, stanowi cykl publikacji naukowych ujętych pod wspólnym tytułem:

Analiza korelacji długozasięgowych szeregów agrometeorologicznych w kontekście modelowania produkcji roślinnej w warunkach zmian klimatu

4.2. Publikacje składające się na osiągnięcie naukowe:

1. Baranowski P., **Krzyszczak J.**, Sławiński C., Hoffmann H., Kozyra J., Nieróbca A., Siwek K., Gluza A. (2015): *Multifractal analysis of meteorological time series to assess climate impacts*. Climate Research, 65, 39-52. <https://doi.org/10.3354/cr01321>
MNiSW – 35 pkt, IF – 1,69, cytowania – 19 (Web of Science) / 20 (Scopus), udział 55%
2. **Krzyszczak J.**, Baranowski P., Hoffmann H., Zubik M., Sławiński C. (2017): *Analysis of climate dynamics across a European transect using a multifractal method*. Rozdział w monografii: Rojas I., Pomares H., Valenzuela O. (eds) „Advances in Time Series Analysis and Forecasting”, ITISE 2016. Contributions to Statistics, Springer, Cham., 103-116. https://doi.org/10.1007/978-3-319-55789-2_8
MNiSW – 15 pkt, IF – 0,0, cytowania – 3 (Web of Science) / 0 (Scopus), udział 80%
3. **Krzyszczak J.**, Baranowski P., Zubik M., Hoffmann H. (2017): *Temporal scale influence on multifractal properties of agro-meteorological time series*. Agricultural and Forest Meteorology, 239, 223-235. <https://doi.org/10.1016/j.agrformet.2017.03.015>
MNiSW – 45 pkt, IF – 4,039, cytowania – 9 (Web of Science) / 9 (Scopus), udział 85%
4. Hoffmann H., Baranowski P., **Krzyszczak J.**, Zubik M., Sławiński C., Gaiser T., Ewert F. (2017): *Temporal properties of spatially aggregated meteorological time series*. Agricultural and Forest Meteorology, 234-235, 247-257. <https://doi.org/10.1016/j.agrformet.2016.12.012>
MNiSW – 45 pkt, IF – 4,039, cytowania – 9 (Web of Science) / 9 (Scopus), udział 45%
5. **Krzyszczak J.**, Baranowski P., Zubik M., Kazandjiev V., Georgieva V., Sławiński C., Siwek K., Kozyra J., Nieróbca A. (2018): *Multifractal characterization and comparison of meteorological time series from two climatic zones*. Theoretical and Applied Climatology, 1-14. <https://doi.org/10.1007/s00704-018-2705-0>
MNiSW – 30 pkt, IF – 2,321, cytowania – 0 (Web of Science) / 2 (Scopus), udział 85%

6. Murat M., Malinowska I., Gos M., **Krzyszczak J.** (2018): *Forecasting daily meteorological time series using ARIMA and regression models*. International Agrophysics, 32(2), 253-264. <https://doi.org/10.1515/intag-2017-0007>
MNiSW – 25 pkt, IF – 1,242, cytowania – 3 (Web of Science) / 3 (Scopus), udział 30%
7. Ruiz-Ramos M., Ferrise R., Rodríguez A., Lorite I.J., Bindi M., Carter T.R., Fronzek S., Palosuo T., Pirttioja N., Baranowski P., Buis S., Cammarano D., Chen Y., Dumont B., Ewert F., Gaiser T., Havlinka P., Hoffmann H., Höhn J.G., Jurecka F., Kersebaum K.C., **Krzyszczak J.**, Lana M., Mechiche-Alami A., Minet J., Montesino M., Nendel C., Porter J., Ruget F., Semenov M.A., Steinmetz Z., Stratonovitch P., Supit I., Tao F., Trnka M., de Wit A., Rötter R.P. (2018): *Adaptation response surfaces for managing wheat under perturbed climate and CO₂ in a Mediterranean environment*. Agricultural Systems, 159, 260-274. <https://doi.org/10.1016/j.agsy.2017.01.009>
MNiSW – 50 pkt, IF – 3,004, cytowania – 16 (Web of Science) / 24 (Scopus), udział 12%

Suma punktów za wymienione wyżej publikacje zgodnie z punktacją MNiSW w poszczególnych latach wydania publikacji wynosi **245**. Sumaryczny **IF** publikacji wchodzących w skład osiągnięcia naukowego według roku opublikowania wynosi **16,335**.

4.3. Omówienie celu naukowego ww. prac i osiągniętych wyników wraz z omówieniem ich ewentualnego wykorzystania:

Wstęp

Według szacunków zawartych w raporcie Departamentu Organizacji Narodów Zjednoczonych do spraw Ekonomicznych i Społecznych *World Population Prospects: The 2017 Revision* (UN DEPA, 2017) w ciągu nadchodzących czterech dekad populacja światowa, obecnie szacowana na 7,6 miliarda, ma wzrosnąć do około 10 miliardów. Organizacja Narodów Zjednoczonych do spraw Wyżywienia i Rolnictwa (FAO, 2016) stawia tezę, iż, aby zaspokoić zwiększające się zapotrzebowanie na żywność powiązane ze wzrostem liczby ludności i nie dopuścić do plagi głodu, produkcja żywności w skali globalnej będzie musiała wzrosnąć przynajmniej o 60 procent w stosunku do obecnego poziomu. Najprostszym sposobem zintensyfikowania produkcji roślinnej i zaspokojenia zapotrzebowania na żywność jest zwiększenie areалу upraw, co jednak nie zawsze jest możliwe. Drugą możliwością jest podniesienie efektywności produkcji rolnej, czy to poprzez redukcję tzw. luki w plonie (z ang. yield gap), czyli różnicy pomiędzy plonem możliwym do uzyskania w optymalnych warunkach wzrostu a plonem uzyskiwanym, czy stosowanie odmian lepiej dopasowanych do danych warunków klimatycznych, bardziej odpornych i dających wyższy plon. Jak stwierdzono w raporcie FAO *How to Feed the World in 2050* (FAO, 2009), w krajach rozwijających się wzrost produkcji rolnej w głównej mierze (w 80%) musiałoby opierać się na zwiększeniu uzyskiwanego plonu, gdyż jedynie 20% wzrostu może wynikać z ekspansji arealu gruntów ornych. Jednak ze względu na bezpośrednią zależność działalności rolniczej od warunków klimatycznych, to właśnie rolnictwo narażone jest najbardziej na skutki zmian zachodzących w klimacie Ziemi w okresie kilku ostatnich dekad. Niezależnie od przekonania, czy zmiany te mają podłoże antropoge-

niczne (są wynikiem działalności człowieka i industrializacji jego życia), czy są przejawem naturalnych cykli zmian w klimacie Ziemi zachodzących od wielu mileniów, charakteryzujących się okresami nagłych ociepleń, po których następował stopniowy spadek temperatury (Benzi, 2010) - czyli tak zwanych zlodowaceń i okresów interglacjalnych, dyskusji nie podlega sam fakt ich obserwacji. Przejawiają się one rosnącymi temperaturami, zarówno w skali lokalnej, jak i globalnej, zmianami w charakterystyce opadów - tak w jego częstotliwości, jak i intensywności, czy w częstotliwości występowania zdarzeń ekstremalnych - fal upałów, susz, burz i powodzi. Zmiany klimatyczne stanowią poważne wyzwanie dla produkcji rolniczej nie tylko w kontekście intensyfikacji produkcji, ale nawet utrzymania jej na obecnym poziomie. Naturalne wydają się wobec tego pytania o to, w jaki sposób zmiany klimatu wpłyną na rolnictwo i jak przemysł rolniczy do tych zmian dostosować.

Jednak, aby na powyższe pytania móc udzielić odpowiedzi, najpierw musimy odpowiedzieć na pytanie, jakich warunków meteorologicznych możemy spodziewać się w danym punkcie przestrzeni za kilka/kilkadziesiąt lat. Główne źródło danych wejściowych do modeli zmian klimatu stanowią zarówno historyczne, jak i współcześnie zarejestrowane dane agrometeorologiczne, które przechowywane są w formie szeregów czasowych. W celu oszacowania odpowiedzi klimatu danego typu na różne możliwe wymuszenia szczególnie istotne stają się więc badania zmienności czasowej i przestrzennej szeregów czasowych wielkości agrometeorologicznych. Standardowe podejście do określania dynamiki klimatu wykorzystuje albo analizę statystyczną prowadzącą do określenia stanu uśrednionego i rozmiarów fluktuacji dookoła tego stanu, albo polega na oszacowaniu trendu i sezonowości szeregu czasowego danej wielkości agrometeorologicznej (Balling i in., 1998). Jednak takie klasyczne podejście daje zadowalające wyniki jedynie w strefach klimatycznych charakteryzujących się ekstremalną dynamiką zmian, a wielu przypadkach standardowo stosowane metody analizy zmienności czasowej danych klimatycznych są niewystarczające do wychwycenia i wyjaśnienia zmian obserwowanych w ich charakterystykach czasowo-przestrzennych. Dlatego też poza standardowymi procedurami do oszacowania dynamiki procesów klimatycznych wykorzystuje się metody bardziej wyrafinowane, takie jak: analiza fraktalna czy teoria chaosu (Kantelhardt i in., 2002; Higuchi, 1988; Kalauzi i in., 2005). Te nowatorskie metody pozwalają na oszacowanie bardziej inherentnych cech danego szeregu, takich jak choćby korelacje długozasięgowe, czyli korelacje, których zanik jest powolny, opisywany funkcją wykładniczą, a nie eksponencjalną. Ten nietypowy, powolny zanik funkcji korelacyjnej ma niezwykle ważne konsekwencje i sugeruje, że badany układ charakteryzuje się albo „efektem pamięci”, albo „samopodobieństwem” (zachowaniem nielokalnym) (Sánchez i in. 2005). Obiekt wykazujący „samopodobieństwo” jest podobny do siebie niezależnie od skali, czyli wygląda tak samo niezależnie od tego, czy jest obserwowany z bliska, czy z pewnej odległości. Zarówno „efekt pamięci”, jak i „samopodobieństwo”, wiążą się z faktem, iż przeszły i odległy czasowo stan systemu ma wpływ na jego teraźniejszą, lokalną ewolucję, a odległe czasowo wydarzenia są statystycznie powiązane ze sobą. Dlatego też badania, czy dany szereg charakteryzuje się korelacjami długozasięgowymi są niezwykle ważne, aby zrozumieć zachowanie systemu w ujęciu globalnym, a oszacowanie wpływu korelacji długozasięgowych na ewolucję systemu - niezwykle pomocne w opisie czasowo-przestrzennej zmienności klimatu w różnych skalach.

Korelacje długozasięgowe mogą być wykryte dzięki analizie gęstości widmowej mocy sygnału, która wykorzystując ciągłą transformatę Fouriera opisuje, jaki jest rozkład częstotliwościowy mocy sygnału (lub szeregu czasowego). Analiza taka przedstawia zawartość częstotliwości w procesie stochastycznym i pozwala na identyfikację występujących w nim wyrażonych okresowości. Składowe częstotliwości tych okresowości niosą użyteczne informacje dotyczące ich „morfologii” i są wskaźnikiem nieliniowości procesów odpowiadających za wygenerowanie danego sygnału (szeregu czasowego). Jeżeli skorelowane struktury długozasięgowe są obecne w danym szeregu, to widmo sygnału przyjmuje kształt krzywej potęgowej. Takie zachowanie nazywane jest skalowaniem, a sama analiza pozwala na określenie siły fluktuacji czasowych w dowolnym procesie poprzez oszacowanie wykładników skalowania (Koscielny-Bunde i in., 1998). Aby scharakteryzować korelacje długozasięgowe w szeregach czasowych w sposób kompleksowy należy obliczyć wykładniki skalowania dla różnych części serii, co oznacza konieczność zastosowania analizy multifraktalnej (Kantelhardt i in., 2006). Analiza multifraktalna rozszerza formalizm fraktalny, umożliwiając identyfikację korelacji długozasięgowych innych niż liniowe. Fundamentem multifraktalnej charakterystyki sygnału jest funkcja rozdziału i własności skalujące tej funkcji odniesione do fluktuacji kumulowanych zgodnie z ich rozmiarem. Multifraktalność w powyższym sensie związana jest ze złożonym zachowaniem objawiającym się różnym skalowaniem dla korelacji różnego rozmiaru. Innymi słowy, multifraktalność jest wskaźnikiem złożonej dynamiki, w przypadku której pojedynczy wykładnik (wymiar fraktalny) nie jest wystarczający, aby w pełni scharakteryzować dany proces, a zamiast tego potrzebne jest ciągle spektrum wykładników, czyli tak zwane widmo multifraktalne lub inaczej - spektrum osobliwości (z ang. singularity spectra). Ponadto, gdy wymiar fraktalny jest liczbą niecałkowitą, szereg czasowy charakteryzuje się dwoma specyficznymi cechami - niejednorodnością, co oznacza występowanie fluktuacji o ekstremalnych amplitudach w nieregularnych odstępach oraz symetrią skalowania, która z kolei określa zależność między fluktuacjami w różnych odstępach czasowych (Scarlat i in., 2007).

Badania dotyczące właściwości skalowania szeregów czasowych wielkości agrometeorologicznych prowadzone do tej pory skupiały się raczej na analizie danych zarejestrowanych na przestrzeni kilku lat, pochodzących z jednej lokalizacji lub z małego obszaru (regionu), i jednym, wybranym elemencie meteorologicznym (Koscielny-Bunde i in., 1998; Kavasseri i Nagarajan, 2005; Király i Jánosi, 2005; Bartos i Jánosi, 2006; García-Marín i in., 2008; de Lima i de Lima, 2009; Feng i in., 2009; Gemmer i in., 2010; Valencia i in., 2010; Jiang i in., 2013; Rodríguez i in., 2013; Yonghe i in., 2013). Dlatego też pojawia się rosnąca potrzeba zbadania właściwości multifraktalnych wieloletnich (co najmniej 30-letnich, aby można było mówić o charakteryzowaniu klimatu) szeregów czasowych wielkości agrometeorologicznych zarejestrowanych w lokalizacjach (lub na obszarach) o zróżnicowanych warunkach klimatycznych.

Cel

Celem przeprowadzonych przeze mnie badań, przedstawionych w cyklu publikacji o spójnej tematyce, było przeanalizowanie właściwości multifraktalnych wieloletnich szeregów czasowych wybranych wielkości agrometeorologicznych zarejestrowanych w lokalizacjach i na obszarach o zróżnicowanym klimacie, aby określić, czy badane szeregi czasowe wykazują właściwości skalowania i charakteryzują się obecnością korelacji długozasięgowych

w ich strukturze. Pozwoliło to wykryć i jakościowo scharakteryzować różnice we właściwościach szeregów pochodzących z lokalizacji o odmiennych warunkach klimatycznych, a tym samym umożliwiło rozszerzenie i uogólnienie opisu różnic w dynamice procesów meteorologicznych zachodzących w różnych strefach klimatycznych i zastosowanie uzyskanej wiedzy w modelowaniu produkcji roślinnej.

Drugim nowatorskim aspektem przeprowadzonych przeze mnie badań było sprawdzenie, czy metoda analizy multifraktalnej szeregów czasowych jest czuła na temporalne zmiany w dynamice danej wielkości agrometeorologicznej poprzez wykonanie analizy porównawczej dwóch podzbiorów danego szeregu. Analiza została wykonana zarówno dla podzbiorów o równej długości serii czasowej (publikacja **I.B.1**), jak i z uwzględnieniem nagłych zmian klimatu zasugerowanych w literaturze – pierwszej około 1980 roku, kiedy zaobserwowano nie tylko zmianę w trendzie temperatury średniej, ale także w wariancji temperatur w okresach przed i po 1980 roku (Huntingford i in., 2013) oraz drugiej, której obecność manifestuje się na przełomie lat 2001/2002 (Swanson i Tsonis, 2009) (publikacje **I.B.2** oraz **I.B.5**).

Analiza multifraktalna została także wykorzystana do określenia, jak lokalne trendy w szeregu meteorologicznym oraz niestacjonarności, takie jak korelacje długozasięgowe, są zachowywane przy zmianie zarówno przestrzennej (publikacja **I.B.3**), jak i czasowej (publikacja **I.B.4**) skali danych agrometeorologicznych.

Praktycznym zastosowaniem przeprowadzonych analiz multifraktalnych wieloletnich szeregów czasowych wybranych wielkości agrometeorologicznych i płynących z tych analiz wniosków było opracowanie metody długoterminowego prognozowania dobowych wartości szeregów agrometeorologicznych zachowujących własności skalowania danego elementu agrometeorologicznego (publikacja **I.B.6**). W kolejnym kroku w długoterminowych prognozach wartości dobowych szeregów czasowych temperatury i opadu zachowujących skalowanie uwzględniono szerokie spektrum scenariuszy zmian klimatu, a otrzymane w ten sposób serie zostały wykorzystane jako dane wejściowe do modeli wzrostu i plonowania roślin, dzięki czemu przeprowadzona została analiza wpływu zabiegów adaptacyjnych na zmiany w produkcji roślinnej w warunkach zmieniającego się klimatu (publikacja **I.B.7**).

Metodyka

Analiza korelacji długozasięgowych szeregów agrometeorologicznych

Spośród wielu metod analizy właściwości fraktalnych szeregów czasowych zaproponowanych w ostatnich latach wyróżnić można analizę odtrendowanych fluktuacji (Detrended Fluctuation Analysis, DFA). Niewątpliwą zaletą metody DFA jest to, iż umożliwia ona scharakteryzowanie liniowych korelacji długozasięgowych w niestacjonarnych szeregach czasowych. Metoda analizy odtrendowanych fluktuacji, tak jak i metoda falkowa, systematycznie usuwa trend występujący w tych szeregach. Trend może prowadzić do nieprawidłowej identyfikacji korelacji długozasięgowych ze względu na swój niestacjonarny charakter. Usunięcie trendu charakteryzującego się powolną zmianą kierunku jest niezbędne, by poprawnie określić niezmienniczość skali struktur, które są na ten trend nałożone. Brak odtrendowania szeregu powodować może niepoprawne oszacowanie wykładników skalowania. Uogólnieniem formalizmu metody DFA rozszerzającym jej stosowalność poprzez umożliwienie określania nieliniowych charakterystyk szeregów czasowych wielkości opisujących różne procesy (Peng i in.,

1994) jest multifraktalna analiza odrendowanych fluktuacji (MultiFractal Detrended Fluctuation Analysis, MF-DFA). W metodzie MF-DFA funkcja rozdziału jest wariancją sygnału lokalnie wielomianowo odrendowanego. Metoda ta umożliwia określenie multifraktalnych właściwości skalowania, a tym samym wykrycia długozasięgowych korelacji (zarówno liniowych jak i nieliniowych) w niestacjonarnych szeregach czasowych charakteryzujących się wysokim poziomem szumów. Zaletą metody multifraktalnej analizy odrendowanych fluktuacji jest niewątpliwie to, iż jest ona mniej czuła na długość szeregu czasowego niż inne metody analizy multifraktalnej, np. metoda maksimum modułu transformaty falkowej (Wavelet Transform Modulus Maxima, WTMM) (Oświęcimka i in., 2006).

Proces usunięcia sezonowości

Okresowości występujące w strukturze danych mogą wpływać na właściwości nieliniowe szeregów czasowych (Livina i in., 2011), a precyzyjniej – na niepoprawne oszacowanie wykładników skalowania danego szeregu czasowego, poprzez wprowadzenie „sztucznej” nieliniowości, tym samym zniekształcając i utrudniając scharakteryzowanie korelacji długozasięgowych. Procedura usuwania okresowości osłabia nieliniowość danego szeregu czasowego, ale rozszerza zakres, w którym obowiązują właściwości skalowania. Oczywistym jest, że szeregi czasowe wielkości agrometeorologicznych wykazują okresowości, które przypisać można choćby rocznemu cyklowi sezonowemu. Dlatego też, przed przeprowadzeniem analizy multifraktalnej szeregów czasowych wielkości agrometeorologicznych, powinno się usunąć występującą w nich sezonowość. W prowadzonych badaniach zdecydowałem się zastosować metodę usuwania okresowości, która do dekompozycji szeregu na składnik sezonowy i trend wykorzystuje regresję lokalną Loess (Seasonal and Trend decomposition using Loess, STL) (Cleveland i in., 1990). Po zastosowaniu procedury STL i rozłożeniu (zdekomponowaniu) szeregu czasowego na składową sezonową, trend oraz składową stochastyczną, komponent sezonowości został pominięty, a pozostałe składniki zsumowane, tworząc w ten sposób „nowy” szereg czasowy. Wysoką skuteczność formalizmu STL jako procedury poprzedzającej multifraktalną analizę odrendowanych fluktuacji MF-DFA i umożliwiającą uzyskać poprawny opis korelacji długozasięgowych potwierdzili Li i in. (2015).

Multifraktalna analiza odrendowanych fluktuacji MF-DFA

Metoda multifraktalnej analizy odrendowanych fluktuacji, zaproponowana w 2002 przez Kantelhardta i in. (2002), polega na wykonaniu pięciu przekształceń dla każdej serii czasowej danych X_i o długości N :

1. Utworzenie profilu $Y(i)$ o długości N , czyli nowego szeregu opisującego błądzenie losowe w analizowanym szeregu, poprzez odjęcie wartości średniej $\langle X \rangle$ od wartości aktualnej X_i i zsumowanie tych różnic:

$$Y(i) = \sum_{i=1}^k [X_i - \langle X \rangle]. \quad k = 1, \dots, N \quad (1)$$

2. Podzielenie profilu $Y(i)$ na $N_s = \text{int}(N/s)$ nienakładających się segmentów o długości s . Ponieważ nie w każdym przypadku długość szeregu N będzie wielokrotnością rozważanej skali czasu s , i w związku z tym krótka część na końcu profilu może nie zostać uwzględniona w analizie, dlatego też tę samą procedurę należy powtórzyć, zaczynając od końca serii. W ten sposób otrzymujemy co prawda $2N_s$ segmentów, ale mamy pewność, że każdy punkt i profilu Y_i jest analizowany.
3. Obliczenie odtrendowanej wariancji $F^2(s, v)$ poprzez wpasowanie metodą najmniejszych kwadratów wielomianu $y_v(i) = \sum_{k=0}^m C_k i^{m-k}$ m -tego stopnia w każdy z $2N_s$ segmentów w celu oszacowania lokalnych trendów, a następnie odjęcie ich od profilu $Y(i)$ w celu jego odtrendowania:

$$F^2(s, v) = \frac{1}{s} \sum_{i=1}^s \{Y([v-1]s + i) - y_v(i)\}^2, \quad v = 1, \dots, N_s \quad (2)$$

$$F^2(s, v) = \frac{1}{s} \sum_{i=1}^s \{Y(N - [v - N_s]s + i) - y_v(i)\}^2. \quad v = N_s + 1, \dots, 2N_s \quad (3)$$

4. Obliczenie uogólnionej funkcji fluktuacji $F_q(s)$ q -tego rzędu poprzez uśrednienie wariancji ze wszystkich $2N_s$ segmentów:

$$F_q(s) = \left\{ \frac{1}{2N_s} \sum_{v=1}^{2N_s} [F^2(s, v)]^{q/2} \right\}^{1/q}. \quad (4)$$

Funkcję fluktuacji należy obliczyć dla różnego rozmiaru segmentów (różnych skal s), by uwzględnić zarówno fluktuacje szybkozmienne (o dużej częstotliwości), których wpływ silnie zaznacza się w przypadku segmentów o małym rozmiarze, oraz fluktuacje wolnozmienne (o małej częstotliwości), których wpływ jest dominujący w przypadku segmentów o dużym rozmiarze.

5. Określenie właściwości skalowania uogólnionych funkcji fluktuacji poprzez analizę wykresów $F_q(s)$ w zależności od skali s dla każdego rzędu fluktuacji q . W przypadku multifraktali $F_q(s)$ opisać można funkcją wykładniczą:

$$F_q(s) \sim s^{h(q)}, \quad (5)$$

z uogólnionym wykładnikiem Hursta $h(q)$ zależnym od q . Wykorzystując równanie:

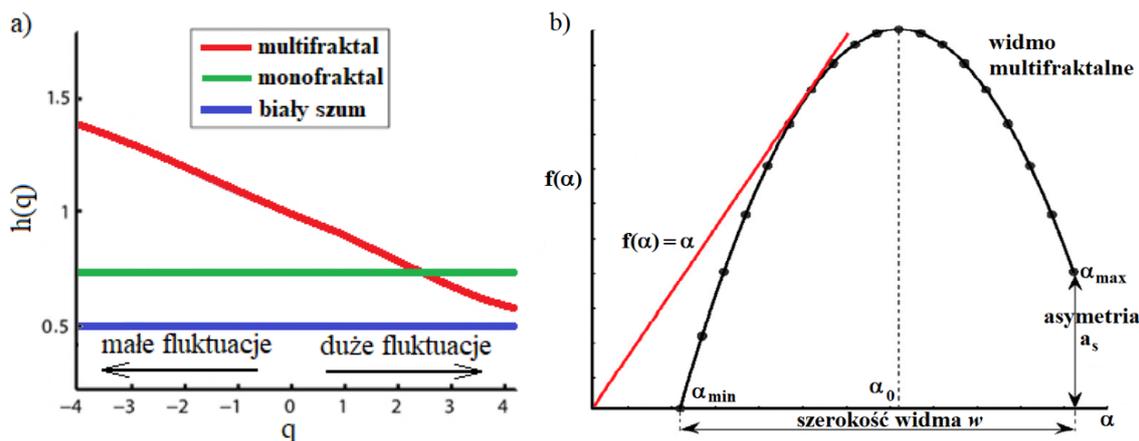
$$\tau(q) = qh(q) - 1, \quad (6)$$

a następnie transformację Legendre'a:

$$\alpha = \frac{d\tau}{dq}, \quad (7)$$

otrzymuje się widmo multifraktalne $f(\alpha)$:

$$f(\alpha) = q\alpha - \tau(q). \quad (8)$$



Rys.1. Schematyczne przedstawienie zależności: a) wykładnika Hursta $h(q)$ od rzędu fluktuacji q dla szeregu czasowego wykazującego właściwości multifraktalne (linia niebieska), monofraktalne (linia czerwona) i będącego białym szumem (linia turkusowa), oraz b) głównych parametrów widma multifraktalnego: α_0 – wartości siły spektrum w jego maksimum, a_s – asymetrii widma, oraz $w = \alpha_{max} - \alpha_{min}$, będącej szerokością widma. Rysunki zostały przygotowane w oparciu o Ihlen (2012).

Przykładowe wykresy ilustrujące w sposób schematyczny zależność uogólnionego wykładnika Hursta $h(q)$ od rzędu fluktuacji q oraz widma multifraktalnego $f(\alpha)$ od jego siły (wykładnika Höldera) α , wraz z zaznaczonymi głównymi parametrami tego widma, przedstawione są na Rys.1. Uogólniony wykładnik Hursta (wymiar fraktalny) $h(q)$ opisuje skalowanie fluktuacji o dużych amplitudach dla dodatnich q , z kolei dla ujemnych q opisuje skalowanie fluktuacji o małych amplitudach. $h(q = 2)$ jest klasycznym wykładnikiem Hursta opisującym liniowe korelacje długozasięgowe. W przypadku szeregów czasowych będących monofraktalami, $h(q)$ przyjmuje jedną, niezależną od rzędu fluktuacji q , wartość. Jeżeli jednak obserwujemy duże zróżnicowanie skalowania pomiędzy fluktuacjami o małych i dużych amplitudach, mamy do czynienia z multifraktalami. Jeżeli:

1. $0 < h(q) < 0,5$ – szereg czasowy charakteryzuje się długozasięgową anty-korelacją, co oznacza, że po wzroście wartości w danym szeregu w kolejnym kroku czasowym bardziej prawdopodobny jest spadek niż wzrost (i odwrotnie, po spadku bardziej prawdopodobny jest wzrost), a szereg jest ergodyczny, czyli jego kolejne wartości oscylują wokół wartości średniej.
2. $h(q) = 0,5$ – szereg czasowy jest nieskorelowany, co oznacza, że prawdopodobieństwo iż po wzroście nastąpi spadek jest takie samo, jak to, że nastąpi wzrost, a szereg jest białym szumem.
3. $h(q) > 0,5$ – szereg czasowy charakteryzuje się korelacją długozasięgową, co oznacza, że wzrostowi wartości w danym szeregu częściej towarzyszy kolejny wzrost niż spadek, a szereg wzmacnia trend.

Widmo multifraktalne ilustruje z kolei występowanie lokalnych wykładników Hursta w strukturze sygnału. Wartość spektrum $f(\alpha)$ określa siłę wkładu każdego z wykładników. Widmo scharakteryzować można za pomocą trzech podstawowych parametrów:

1. α_0 – wartość siły spektrum w jego maksimum, która wskazuje, jakie skalowanie jest najbardziej powszechne w danym szeregu. Im niższa jest wartość tego parametru, tym proces leżący u podstaw danego zjawiska jest bardziej skorelowany, co oznacza utratę struktury subtelnej, to jest szczegółów (nieregularności) w dowolnie małej skali, a tym samym - większą regularność przebiegu danego szeregu czasowego.
2. α_s – asymetria widma, która przyjmuje wartości ujemne dla widma lewoskośnego, dodatnie dla widma prawoskośnego i jest równa zero dla widma symetrycznego. Widmo lewoskośne oznacza, że niskim wykładnikom fraktalnym przypisywana jest mała waga, co sugeruje z kolei częste występowanie zdarzeń ekstremalnych (Telesca i Lovallo, 2011). Lewoskośność sugeruje istnienie w serii złożonych struktur na poziomie dużych amplitud fluktuacji, a szeregi czasowe charakteryzują się strukturą multifraktalną, która jest niewrażliwa na lokalne fluktuacje o niewielkich amplitudach. Widmo prawoskośne oznacza dużą wagę wysokich wykładników fraktalnych, które odpowiadają strukturze subtelnej szeregu (szeregi czasowe charakteryzują się strukturą multifraktalną, która jest niewrażliwa na lokalne fluktuacje o dużych amplitudach).
3. w – szerokość widma, która jest różnicą pomiędzy α_{max} , czyli wymiarem fraktalnym odpowiadającym najbardziej łagodnym, a α_{min} , czyli wymiarem fraktalnym odpowiadającym najbardziej gwałtownym procesom w analizowanym szeregu. Szerokość widma określa zakres wykładników fraktalnych w sygnale, a tym samym - siłę dynamiki multifraktalnej. Im większa jest szerokość widma, tym większa jest różnorodność poszczególnych fraktali, które składają się na badany multifraktal, co oznacza większe „bogactwo” i większą złożoność struktury sygnału (bardziej rozwiniętą multifraktalność). Monofraktales charakteryzują się widmem o zerowej szerokości (czyli widmem będącym pojedynczym punktem).

Multifraktalność danego szeregu czasowego może mieć dwa źródła: albo jest indukowana przez szerokość (ogony) nie-gaussowskiej funkcji gęstości prawdopodobieństwa, albo jest wynikiem istnienia korelacji długozasięgowych w fluktuacjach o małych i dużych amplitudach (Kantelhardt i in., 2002). Istotnym wydaje się więc określenie, co odpowiada za multifraktalność danego sygnału (szeregu czasowego). W tym celu przekształca się zarejestrowaną serię w taki sposób, by pewne cechy szeregu usunąć, zachowując bez zmian inne jej właściwości, a następnie porównuje się widma multifraktalne serii oryginalnej i serii przetransformowanej, w szczególności ich szerokości. W pracy wykorzystano dwa sposoby transformacji danych:

1. Losowe przestawienia kolejności (Random Shuffle, RS), która pozwala na usunięcie korelacji długozasięgowych w zarejestrowanym szeregu o ustalonej chronologii poprzez wykonanie przypadkowych przestawień (permutacji) pozycji czasowych w tablicy rekordów. Pozwala to uzyskać nowy szereg charakteryzujący się identyczną funkcją gęstości prawdopodobieństwa, a nie posiadający chronologii – a tym samym korelacji długozasięgowych. Jeżeli po analizie multifraktalnej tak przekształconego szeregu otrzymamy monofraktal, to oznacza to, że za multifraktalność odpowiedzialne są jedy-

nie korelacje długozasięgowe, jeżeli natomiast rozkład funkcji gęstości prawdopodobieństwa jest głównym źródłem multifraktalności, to wygląd widma nie powinien ulec zmianie. Jeżeli szerokość widma przekształconego szeregu jest mniejsza niż szerokość widma szeregu z zachowaną chronologią, to oznacza to, że zarówno szerokość funkcji gęstości prawdopodobieństwa, jak i korelacje długozasięgowe są źródłem multifraktalności danego szeregu.

2. Transformacja Fouriera z korekcją amplitudy (Amplitude Adjusted Fourier Transform, AAFT), która pozwala na zachowanie zarówno liniowej struktury korelacji, jak i rozkładu funkcji gęstości prawdopodobieństwa, poprzez zastosowanie transformacji Fouriera z losowymi fazami (Theiler et al., 1992). Dzięki tej transformacji można ocenić wpływ korelacji nieliniowych na multifraktalność danego szeregu czasowego.

Długoterminowa prognoza szeregów czasowych zachowujących własności skalowania

W pracy dotyczącej opracowania metody prognozy długoterminowej dobowych wartości szeregów agrometeorologicznych zachowujących własności skalowania danego elementu agrometeorologicznego (publikacja **I.B.6**) posługiwałem się dwoma modelami regresyjnymi oraz dwoma modelami bazującymi na zintegrowanym modelu autoregresyjnym ze średnią ruchomą (AutoRegressive Integrated Moving Average, ARIMA) (Box and Jenkins, 1970; Box and Tiao, 1975). Modele takie pozwalają na wykrycie różnych struktur w szeregu czasowym, na przykład wskazują na obecność trendu czy wahań sezonowych. Pierwszym z grupy modeli ARIMA był zintegrowany sezonowy model autoregresyjny ze średnią ruchomą (Seasonal AutoRegressive Integrated Moving Average, SARIMA), drugim - zintegrowany model autoregresyjny ze średnią ruchomą z rezyduami zmodyfikowanymi Fouriersko (Fourier Residual Modified AutoRegressive Integrated Moving Average, ARIMAF) (Nguyen i in., 2013). Modele te składają się z trzech podstawowych elementów:

- procesu autoregresyjnego AR,
- stopnia integracji I,
- procesu średniej ruchomej MA.

Proces autoregresyjny jest procesem, w którym każda kolejna wartość jest liniową kombinacją wartości poprzednich, czyli procesem wykorzystującym „pamięć” układu. O rzędzie autoregresji p mówi nam to, ile poprzednich wartości ma wpływ na wartość kolejną. Proces średniej ruchomej jest z kolei regresją liniową bieżącej wartości szeregów w odniesieniu do poprzedzających tę wartość i niezaobserwowanych czynników błędu ε , związanych albo z białym szumem, albo z przypadkowymi zaburzeniami. Rząd procesu średniej ruchomej określa parametr q , który informuje, jak wiele wcześniejszych niezaobserwowanych czynników błędu uwzględniamy. Modele ARIMA możemy stosować do szeregów niestacjonarnych, ale tylko takich, które możemy sprowadzić do postaci stacjonarnej (czyli takiej, która ma stały w czasie poziom - średnią, oraz odchylenie od tego poziomu - wariancję). To, ile przekształceń jest potrzebnych, by sprowadzić szereg niestacjonarny do stacjonarnego, określa parametr d . Modele SARIMA oraz ARIMAF rozszerzają formalizm modelu ARIMA poprzez uwzględnienie składowej sezonowości. W modelu SARIMA sezonowość uwzględnia się przemnażając niesezonowe składniki modelu przez składniki opisujące wahania sezonowe. Tym samym w modelu

SARIMA pojawiają się trzy nowe hiper-parametry P , D i Q , które pozwalają określić proces autoregresyjny (AR), stopień integracji (I) i proces średniej ruchomej (MA) dla komponentu sezonowego serii, oraz dodatkowy parametr m definiujący okres sezonowości. Sezonowe procesy AR oraz MA przewidują kolejną wartość za pomocą liniowej kombinacji wartości (AR) lub błędów (MA) odległych w szeregu o wielokrotność okresu sezonowości m , a sezonowy stopień integracji mówi o ilości przekształceń potrzebnych, by usunąć występujący w komponencie sezonowości trend, oraz pozbyć się niestacjonarności typu błędzenia losowego, a tym samym sprowadzić komponent sezonowy do postaci stacjonarnej. Sezonowy model SARIMA(p, d, q)(P, D, Q) $_m$ można zapisać jako:

$$\Phi(B^m)\phi(B)(1 - B^m)^D(1 - B)^d Y_t = c + \Theta(B^m)\theta(B)\varepsilon_t, \quad (9)$$

gdzie komponenty niesezonowe zdefiniować można jako:

$$\text{AR: } \phi(B) = 1 - \phi_1 B - \dots - \phi_p B^p, \quad \text{MA: } \theta(B) = 1 + \theta_1 B + \dots + \theta_q B^q, \quad (10)$$

a komponenty sezonowe jako:

$$\text{sAR: } \Phi(B^m) = 1 - \Phi_1 B^m - \dots - \Phi_p B^{mP}, \quad \text{sMA: } \Theta(B^m) = 1 + \Theta_1 B^m + \dots + \Theta_q B^{mQ}, \quad (11)$$

z operatorem wstecznym B zdefiniowanym jako $B^k(X_t) = X_{t-k}$. Natomiast w modelu ARIMA, aby zwiększyć poziom dokładności, minimalizuje się reszty (błędy prognozy) poprzez ich modyfikację szeregiem Fouriera. Oznacza to, że do wyniku Y_t z modelu ARIMA (lub SARIMA) dodaje się regresor:

$$Y_t^F = c + \sum_{l=1}^K \left[\alpha_l \sin \frac{2\pi l t}{m} + \beta_l \cos \frac{2\pi l t}{m} \right] + Y_t, \quad (12)$$

w którym α_l i β_l są współczynnikami Fouriera z wartością K dobieraną w taki sposób, by reszty były jak najmniejsze. Otrzymany model oznacza się jako ARIMAF(p, d, q)[K].

Modele regresyjne zastosowane w publikacji mają ogólną postać:

$$Y_t = b_t + s_t + \varepsilon_t. \quad (13)$$

W modelu regresyjnym wielomianowym (Regression Model Polynomial, RMP) trend b_t jest dopasowywany za pomocą wielomianu n -tego stopnia, z czasem t będącym predyktorem:

$$b = \gamma_0 + \gamma_1 t + \gamma_2 t^2 + \dots + \gamma_n t^n, \quad (14)$$

którego stopień n jest tak dobierany, by zminimalizować błędy. Natomiast w modelu regresyjnym z szeregiem Fouriera (Regression Model Fourier, RMF) komponent sezonowości s_t określany jest przy pomocy równania:

$$s_t = \sum_{l=1}^K \left(\alpha_l \cos \frac{2\pi l t}{m} + \beta_l \sin \frac{2\pi l t}{m} \right), \quad (15)$$

z wartością K dobieraną empirycznie w celu minimalizacji błędu predykcji.

Modelowanie produkcji roślinnej w warunkach zmian klimatu

W publikacji dotyczącej analizy wpływu zabiegów adaptacyjnych na zmiany w produkcji roślinnej w warunkach zmieniającego się klimatu (publikacja **I.B.7**) zaprezentowano wyniki zastosowania uśredniania po zespole (ensemble modeling) 14 modeli wzrostu, rozwoju i plonowania pszenicy ozimej, wykorzystując w tym celu zmodyfikowaną metodę powierzchni odpowiedzi (Impact Response Surfaces, IRS) uwzględniającą zabiegi adaptacyjne, opracowaną na potrzeby publikacji.

Modele wzrostu, rozwoju i plonowania roślin

Modele wzrostu, rozwoju i plonowania roślin stanowią nie tylko przydatne narzędzie mogące służyć do wyjaśniania skomplikowanych uwarunkowań plonotwórczych, ale służą także jako metoda pośrednia szybkiego otrzymania informacji, których pozyskanie w inny sposób wymagałoby wykonania wieloletnich eksperymentów polowych (Mądry, 1995). Modele te są schematycznym przedstawieniem koncepcji działania układu gleba-roślina-atmosfera, przełożonymi na algorytm komputerowy mający w rezultacie opisywać przyrost biomasy (Hoogenboom i in., 2004). W tym celu wykorzystują równania matematyczne będące hipotezami ilościowymi dotyczącymi obserwowanej rzeczywistości, które mają za zadanie reprezentować zachowanie określonej części układu. Jednak w rzeczywistości wartość biomasy kumulowanej przez roślinę jest rezultatem interakcji pomiędzy wieloma czynnikami, zarówno atmosferycznymi (warunki meteorologiczne), glebowymi (rodzaj podłoża i jego właściwości fizykochemiczne, dostępność składników pokarmowych, itp.), jak i fizjologicznymi. Opis zjawisk zachodzących w takim układzie jest więc niezwykle skomplikowany. Modele matematyczne starają się maksymalnie uprościć opis rozwoju rośliny, zarówno poprzez zastosowanie przybliżeń, jak i ograniczanie zestawu parametrów kontrolujących ten rozwój. Jest to związane z faktem, iż modele symulacyjne nie są uniwersalnie dopasowane do dowolnych warunków środowiska wzrostu roślin, a w określonych warunkach wzrost i rozwój danej odmiany może mieć inny przebieg, co powoduje, iż w modelu bardziej skomplikowanym należy sparametryzować znacznie większą liczbę zmiennych charakteryzujących warunki przyrodnicze oraz właściwości gatunków i odmian roślin. Oszacowanie każdego parametru jest obarczone błędem, a błędy poszczególnych oszacowań kumulują się i wpływają na ostateczny wynik (plon). Często okazuje się więc, iż korzystając z modeli bardziej skomplikowanych uzyskujemy gorsze wyniki, niż stosując model teoretycznie prostszy (Anderson i in., 2014).

W konstrukcji różnych modeli matematycznych wyraźnie zaznacza się zróżnicowana strategia podejścia do strukturyzacji i parametryzacji podstawowych procesów wpływających na rozwój, wzrost i plonowanie roślin (Asseng i in., 2013). Jednak znaczna część modeli opiera się na podobnej koncepcji opisu rozwoju fenologicznego (Hodges, 1990). Jest ona związana z obserwacjami, iż podczas lat cieplejszych rośliny rozwijają się znacznie szybciej, niż podczas lat chłodniejszych, a występowanie kolejnych faz rozwojowych jest przyspieszone w czasie. Dlatego też w modelach wiąże się rozwój rośliny z liczbą stopniodni (degree days), potrzebnych do przejścia do kolejnych faz rozwojowych. Matematycznie opis ten realizowany jest za pomocą sumy temperatur efektywnych T_{sum} . Jest to parametr fenologiczny uwzględniający

wpływ temperatury na tempo rozwoju rośliny i posiada zwykle dwa progi. Dolny próg rozwojowy określa średnią temperaturę dobową, poniżej której rozwój rośliny nie zachodzi, górny z kolei jest temperaturą, dla której rozwój osiąga maksymalne tempo. Temperatury wyższe niż górny próg nie powodują szybszego rozwoju rośliny. Pomiedzy tymi dwoma progami zakłada się najczęściej liniową tendencję wzrostu tempa rozwoju. Na podstawie sumy (przyrostów) temperatury efektywnej T_{sum} określa się bezwymiarowy parametr DVS (DeVelopment Stage) identyfikujący aktualną fazę rozwojową, a osiągnięcie faz 0 (wschód), 1 (kwitnienie) i 2 (dojrzałość) wymaga osiągnięcia odpowiedniej wartości T_{sum} (Bonhomme, 2000). Poszczególne sumy temperatur (pomiedzy siewem a wschodem, wschodem a kwitnieniem oraz kwitnieniem a dojrzałością) zwykle są parametrami w modelu. Z kolei akumulacja biomasy opisywana jest najczęściej poprzez uwzględnienie energii fotosyntetycznej czynnej docierającej do rośliny (PAR), oraz indeksu powierzchni liści (LAI) wraz z ich właściwościami fotosyntetycznymi. Parametry związane z tymi wielkościami, uzupełnione o współczynniki korekcyjne związane z dostępnością (nadmiarem lub niedoborem) wody w strefie korzeniowej (najczęściej poprzez obliczenie transpiracji potencjalnej i aktualnej), oraz ewentualnym brakiem makroskładników, służą do oszacowania całkowitej dziennej wartości asymilacji CO_2 . Jest ona następnie przeliczana na masę asymilatów dostępnych roślinom do tworzenia suchej masy i rozdzielana pomiedzy poszczególne organy roślinne (korzeń, łodygę, liść i kłos) zgodnie z wartościami współczynników rozdziału tych asymilatów. Wartość współczynników rozdziału uzależniona jest zwykle w modelach od aktualnej fazy rozwojowej rośliny (Wilkerson i in., 1981). W modelowaniu akumulacji biomasy często uwzględnia trzy poziomy produktywności:

- potencjalny, uwzględniający jedynie wpływ głównych czynników determinujących rozwój (temperatura, promieniowanie słoneczne, koncentracja CO_2 w atmosferze, genetyczne cechy danej rośliny),
- aktualny z uwzględnieniem dostępności wody glebowej,
- aktualny z uwzględnieniem dostępności wody glebowej oraz składników pokarmowych.

Uśrednianie po zespole modeli

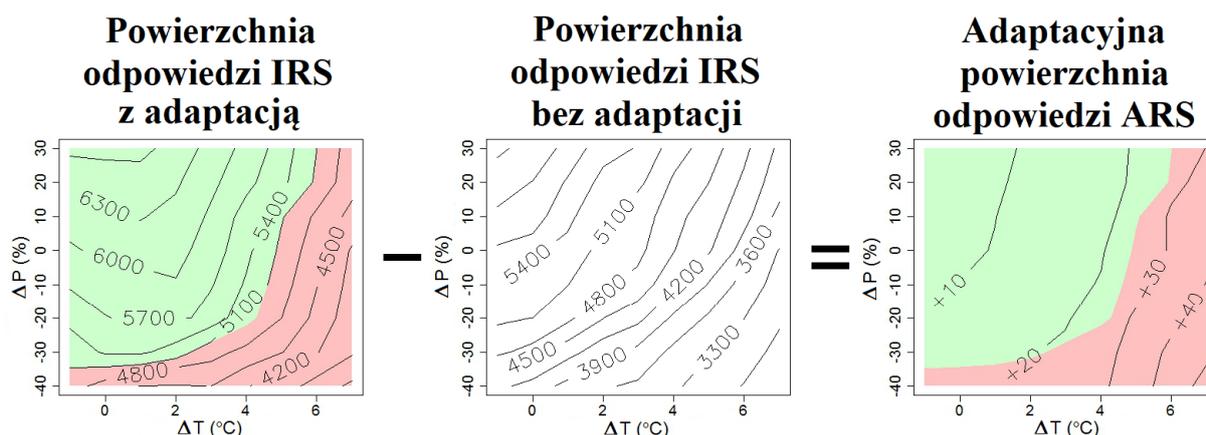
Różne modele różnią się od siebie stopniem złożoności modułów zastosowanych do opisu poszczególnych komponentów układu gleba-roślina-atmosfera i zachodzących w tym układzie interakcji, np. niektóre z nich opisują procesy zachodzące w glebie w sposób uproszczony, traktując ją jako jednowarstwowy ośrodek o ustalonej pojemności polowej, inne uwzględniają jej warstwową budowę i poziomy genetyczne. Z kolei transport wody w glebie może opierać się na teoretycznie poprawnym fizycznym opisie zjawiska transportu wody w ciążach porowatych, czyli równaniu Richardsa, albo wykorzystywać prosty model kubełkowy (soil water bucket model), w którym bilans wodny danej warstwy jest tworzony poprzez zsumowanie wkładów od procesów dostarczających wodę do tej warstwy i odjęcie wody z warstwy wpływającej czy tej pobieranej przez roślinę. Niektóre modele uwzględniają przyrost i obumieranie korzeni, inne obieg węgla w glebie albo procesy nityfikacji i denityfikacji. Jednak żaden model nie potrafi idealnie odtworzyć rozwoju rośliny w zróżnicowanych środowiskach (Palo-suo i in., 2011), a różnice w złożoności konstrukcji modeli stanowią dodatkowe, istotne, źródło

niepewności oszacowania plonów nawet w obecnych warunkach (White i in., 2011). Aby poradzić sobie z tym problemem, w ostatnich latach wykorzystuje się uśrednianie po zespole wielu modeli (ensemble modeling). Uśredniając wyniki pochodzące z wielu modeli, posiadających zróżnicowany stopień złożoności, zwykle uzyskuje się rezultat dokładniejszy, niż używając pojedynczego, przypadkowo wybranego modelu. Jest to związane z kompensacją różnego stopnia złożoności i dokładności parametryzacji poszczególnych modeli w grupie (Martre i in., 2015). Metoda uśrednienia po zespole polega na zamodelowaniu wzrostu, rozwoju i plonowania roślin wieloma różnymi dostępnymi modelami, z założeniem, iż modele pracują w identycznych warunkach środowiskowych, i kalibrowane były z ustaloną hierarchią ważności wielkości kalibrowanych. Następnie dla uzyskanych wyników oblicza się medianę (ewentualnie wartość średnią) oraz inne wielkości statystyczne, takie jak współczynnik zmienności czy odchylenie standardowe. Ten sposób postępowania jest użyteczny w szczególności w modelowaniu produkcji roślinnej w warunkach zmian klimatu (Asseng i in., 2015), w których to warunkach odpowiedzi modeli mogą bardzo od siebie odbiegać. Zastosowanie uśredniania po zespole pozwala nie tylko na identyfikację odpowiedzi najbardziej prawdopodobnej (najczęściej powtarzającej się), ale także na wykonanie analizy czułości na międzyroczne zmiany w warunkach klimatycznych.

Metoda powierzchni odpowiedzi

Zarówno metoda powierzchni odpowiedzi (Impact Response Surfaces, IRS), jak i jej modyfikacja - metoda adaptacyjnych powierzchni odpowiedzi (Adaptation Response Surfaces, ARS), umożliwiają przeprowadzenie szybkiej i jednoczesnej analizy wpływu wielu różnych scenariuszy zmian klimatu na wzrost, rozwój i plonowanie roślin oraz pozwalają na skuteczne wyodrębnienie i sklasyfikowanie istotnych różnic w odpowiedziach modeli plonowania roślin na prognozowane zmiany klimatu (Luo i in., 2007; Ruane i in., 2014). ARS pozwala dodatkowo na skuteczną ocenę wpływu zaplanowanych zabiegów adaptacyjnych na uzyskiwane plony. Powierzchnie odpowiedzi IRS tworzy się wykreślając na płaszczyźnie zmiany danego wskaźnika $f(x,y)$ (zmiennej endogenicznej, zmiennej prognozowanej lub jeszcze inaczej - zmiennej odpowiedzi) dla szerokiego spektrum zmian czynników x i y (zmiennych egzogenicznych, zmiennych objaśniających) (Fronzek i in., 2010). W przypadku modeli wzrostu, rozwoju i plonowania roślin powierzchnie odpowiedzi pozwalają na określenie wpływu zmian wartości elementów meteorologicznych (takich jak temperatura czy opad, ale też koncentracji CO₂ w atmosferze - zmiennych objaśniających) w zakresach prognozowanych przez różne scenariusze zmian klimatu na uzyskiwany plon (zmienna prognozowana). IRS uzyskuje się uruchamiając wielokrotnie model ze zmodyfikowanymi, w zadanym zakresie, danymi wejściowymi (będącymi zmiennymi objaśniającymi) i zapisując wynik, czyli wartość zmiennej prognozowanej.

Z kolei adaptacyjne powierzchnie odpowiedzi służą do oceny, jak na zmienną prognozowaną wpływają wybrane modyfikacje (adaptacje). W przypadku modeli wzrostu i plonowania roślin adaptacyjne powierzchnie odpowiedzi pozwalają oszacować jak na uzyskiwany plon w warunkach zmian klimatu wpływają np. zabiegi agrotechniczne. Tworząc ARS, oblicza się różnicę pomiędzy dwiema powierzchniami odpowiedzi IRS, pierwszą utworzoną, gdy w modelu uwzględniana jest oceniana adaptacja, a drugą utworzoną dla tych samych warunków środowiskowych bez opcji adaptacyjnej (rys. 2). Uzyskany wynik, wyrażony w procentach albo



Rys.2. Schematyczne przedstawienie konstrukcji powierzchni adaptacyjnej ARS. ARS jest wynikiem odjęcia dwóch powierzchni odpowiedzi IRS, jednej z uwzględnieniem adaptacji, a drugiej bez opcji adaptacyjnej. W prezentowanym przypadku wyniki ARS wyrażone są jako procentowa wartość zmiany w stosunku do opcji bez adaptacji. Obie powierzchnie IRS utworzone zostały dla tych samych warunków środowiskowych, co pozwala na ocenę wpływu jedynie wybranej adaptacji. Kolory naniesione na powierzchnie: IRS z adaptacją oraz ARS wskazują, czy plon uzyskany w analizowanych warunkach jest większy (zielony) czy mniejszy (czerwony) niż wartość referencyjna plonu, którą najczęściej jest wartość uzyskana dla aktualnych warunków meteorologicznych (rysunek pochodzi z pracy **I.B.7**).

jako wartość bezwzględna, pozwala ocenić wpływ jedynie danego zabiegu agrotechnicznego (adaptacji) na zmianę wielkości plonu.

Opis badań i otrzymanych wyników

Badania opisane poniżej są wynikiem mojej pracy nad wykorzystaniem multifraktalnej analizy odtrendowanych fluktuacji MF-DFA do scharakteryzowania korelacji długozasięgowych w szeregach czasowych wybranych wielkości agrometeorologicznych dla lokalizacji i obszarów o zróżnicowanym klimacie, a także praktycznym zastosowaniem uzyskanych rezultatów. Przeprowadzone analizy umożliwiły mi opracowanie metody długoterminowej prognozy dobowych wartości szeregów agrometeorologicznych zachowujących własności skalowania prognozowanego elementu agrometeorologicznego, a następnie zamodelowanie produkcji roślinnej w warunkach zmieniającego się klimatu. Publikacje, będące wynikiem przeprowadzonych badań i uzyskanych rezultatów, powstały częściowo we współpracy międzynarodowej z naukowcami z Niemiec, Bułgarii, Finlandii, Hiszpanii i innych państw.

Publikacja **I.B.1** pt. „Multifraktalna analiza szeregów czasowych wielkości meteorologicznych w celu oceny wpływu klimatu” („Multifractal analysis of meteorological time series to assess climate impacts”)

Problem badawczy

W pierwszym etapie badań nad właściwościami multifraktalnymi szeregów czasowych wielkości agrometeorologicznych skupiłem się na przeprowadzeniu analiz dla wieloletnich szeregów czasowych wybranych elementów meteorologicznych, zarejestrowanych w kilku różnych lokalizacjach w Europie, charakteryzujących się odmiennymi warunkami klimatycznymi.

Przeprowadzona analiza miała na celu wykrycie i jakościowy opis różnic w dynamice procesów meteorologicznych zachodzących zarówno w obrębie różnych elementów meteorologicznych, jak i w zróżnicowanych strefach klimatycznych. Dodatkowo, aby sprawdzić, czy metoda analizy multifraktalnej szeregów czasowych jest wrażliwa na ewolucję dynamiki danego procesu agrometeorologicznego, wykonałem analizę porównawczą dla dwóch podzbiorów danego szeregu o równej długości serii czasowej (**I.B.1**).

W czasie gdy rozpocząłem prace nad artykułem, większość badań dotyczących właściwości skalowania szeregów czasowych wielkości agrometeorologicznych skupiała się raczej na analizie danych zarejestrowanych na przestrzeni zaledwie kilku lat. Dane zwykle pochodziły z jednej lokalizacji lub z małego obszaru (regionu), a analizy były sporządzone dla wybranego elementu meteorologicznego. Ponieważ wyniki tych analiz dotyczyły albo innych lokalizacji, albo innych okresów, to spojrzenie holistyczne było znacznie utrudnione. Przeprowadzenie spójnej analizy umożliwiającej porównanie właściwości skalowania różnych wielkości meteorologicznych, zarejestrowanych w lokalizacjach charakteryzujących się odmiennymi warunkami klimatycznymi, było główną przesłanką do podjęcia badań.

Opisywana publikacja (**I.B.1**) była pierwszą pracą, w której dokonano porównania w tak szerokiej skali różnic w dynamice procesów meteorologicznych zachodzących zarówno w obrębie elementów meteorologicznych, jak i w rozmaitych strefach klimatycznych, a także zbadano ewolucję dynamiki różnych procesów agrometeorologicznych.

Badania własne

W pracy dokonałem analizy własności skalowania szeregów czasowych zarejestrowanych w czterech krajach charakteryzujących się zróżnicowanymi warunkami klimatycznymi: Hiszpanii, Niemczech, Polsce i Finlandii, w sześciu lokalizacjach (po dwie lokalizacje w Niemczech i Polsce). Aby można było mówić o scharakteryzowaniu klimatu w danej lokalizacji, analizę przeprowadziłem dla dobowych, 31-letnich szeregów czasowych z okresu 1980-2010. Badałem właściwości skalowania pięciu elementów meteorologicznych: temperatury i wilgotności powietrza, opadu, prędkości wiatru, oraz natężenia promieniowania słonecznego. Wielkości te rejestrowane były we wszystkich lokalizacjach przy pomocy porównywalnej aparatury o tym samym standardzie pomiaru (WMO). W celu zbadania i porównania właściwości skalowania wybranych szeregów czasowych wielkości meteorologicznych zastosowałem metodę MF-DFA. Dla każdego szeregu określiłem zależność uogólnionego wykładnika Hursta od rzędu korelacji oraz obliczyłem trzy podstawowe parametry charakteryzujące widmo multifraktalne. Określiłem także źródło multifraktalności każdego szeregu. Aby ustalić, czy metoda multifraktalna jest w stanie wykryć zmiany w dynamice procesów, analizowane szeregi podzieliłem na dwa podzbiory o równej długości: jeden zawierający dane z okresu 1980-1995, a drugi z 1996-2010, a następnie przeprowadziłem analizę porównawczą podstawowych parametrów charakteryzujących widmo multifraktalne obydwu podzbiorów.

Wyniki, podsumowanie i wnioski

Widma osobliwości otrzymane dla analizowanych szeregów czasowych jednoznacznie wskazują, iż elementy meteorologiczne wykazują multifraktalną strukturę sygnału i posiadają

swoistą dynamikę czasowo-przestrzenną, która może być powiązana z warunkami klimatycznymi. Wynik ten potwierdza analiza parametrów charakteryzujących widmo multifraktalne, która ujawnia duże ich podobieństwo dla elementów meteorologicznych zarejestrowanych w lokalizacjach z tego samego kraju. Jednocześnie różnorodność fraktali, a tym samym złożoność struktury sygnału, oceniona dzięki analizie szerokości spektrum, różni się znacznie, w porównaniu z innymi stacjami, zarówno dla lokalizacji w Finlandii, jak i w Hiszpanii. Wyniki te sugerują, iż metoda MF-DFA nadaje się do oceny różnic w dynamice procesów meteorologicznych dla lokalizacji o zróżnicowanych warunkach klimatycznych. Ponadto, analiza parametrów charakteryzujących widmo multifraktalne wyraźnie wskazuje na różnice w dynamice czasowo-przestrzennej pomiędzy elementami meteorologicznymi. Niezależnie od lokalizacji, opad charakteryzował się najniższymi wartościami α_0 , czyli siły spektrum w jego maksimum, co oznacza silniejszą korelację procesu leżącego u podstaw tego zjawiska. Z kolei najwyższym bogactwem sygnału, a tym samym największą jego złożonością oraz najsilniejszą prawoskośnością, czyli strukturą subtelną szeregu, charakteryzuje się natężenie promieniowania słonecznego. Niezwykle istotny wynik otrzymałem przeprowadzając analizę źródła multifraktalności, która wskazała, że właściwości skalowania opadu znacznie różnią się od właściwości skalowania innych analizowanych elementów meteorologicznych. Dla większości badanych wielkości meteorologicznych multifraktalność pochodzi, w znacznie mierze, od obecności korelacji długozasięgowych w strukturze ich szeregów czasowych, a ogony w funkcji gęstości prawdopodobieństwa są dominującym źródłem multifraktalności jedynie dla opadu. Przewiduje się, że zmiany klimatyczne zmodyfikują zarówno intensywność, czas trwania, jak i częstotliwość zjawisk pogodowych. Silniejsza zależność multifraktalności opadu od funkcji rozkładu gęstości prawdopodobieństwa może oznaczać, że spośród badanych elementów meteorologicznych, to jego właściwości skalowania będą najsilniej uzależnione od zmian w dynamice klimatu. Uzyskane wyniki potwierdzają analizy przeprowadzone dla szeregów podzielonych na dwa podzbiory. Analiza porównawcza wskazuje na większe zmiany parametrów asymetrii i szerokości widma opadu niż innych wielkości meteorologicznych. Z analizy porównawczej wynika, że metoda multifraktalna jest wrażliwa na ewolucję dynamiki procesów meteorologicznych, wskazując na różnice w strukturze sygnałów pomiędzy podokresami. Nie udało mi się jednak wyciągnąć wniosku o ogólnym trendzie tej ewolucji, gdyż ich kierunek zależał zarówno od elementu meteorologicznego, jak i od lokalizacji.

Publikacja I.B.2 pt. „Analiza dynamiki klimatu w transekcje europejskim wykorzystująca metodę analizy multifraktalnej” („Analysis of climate dynamics across a European transect using a multifractal method”)

Problem badawczy

Brak ogólnego trendu zmian w analizie porównawczej właściwości multifraktalnych dwóch podzbiorów danego szeregu, przeprowadzonej w publikacji I.B.1, sprawił, iż zacząłem zastanawiać się, czy pierwotny podział szeregu na dwie równe części był najlepszym z możliwych wyborów. Decyzja o analizie podzbiorów o równej długości serii podyktowana była znaną mi informacją o ograniczeniach metody multifraktalnej w analizie szeregów czasowych o niewielkiej długości serii, która, wraz z malejącą reprezentacją analizowanego zbioru, daje

w rezultacie systematycznie rosnące wartości błędów oszacowania uogólnionych wykładników Hursta $h(q)$ dla korelacji o wysokim rzędzie q (Kantelhardt, 2002). Jednocześnie w literaturze klimatologicznej pojawiały się informacje, iż w ostatnich dekadach zaobserwowano nagłe zmiany w klimacie (Swanson i Tsonis, 2009; Huntingford i in., 2013). Dokonałem więc przeglądu literatury w poszukiwaniu informacji o minimalnej ilości punktów empirycznych szeregu czasowego, jaki może być użyty w analizach. Z przeglądu wynikało, że multifraktalna analiza odtrendowanych fluktuacji jest mniej czuła na długość szeregu czasowego niż inne metody analizy multifraktalnej (Oświęcimka i in., 2006). Szczegółowa analiza wpływu długości szeregów czasowych na dokładność oszacowania $h(q)$ przeprowadzona dla metody MF-DFA (López i Contreras, 2013) pokazywała, iż dla serii o długości 1024 punktów empirycznych błąd oszacowania $h(q)$ jest mniejszy niż 5% dla $|q| \approx 5$ i maleje wraz z analizą własności skalowania dla wykładników $q \rightarrow 0$. Z kolei z pracy Cristescu i in. (2007) wynikało, iż analiza multifraktalna daje wiarygodne wyniki dla szeregów czasowych o długości około 4000 punktów empirycznych. Informacje te utwierdziły mnie w przekonaniu, iż badania ewolucji dynamiki procesów meteorologicznych można powtórzyć z takim podziałem serii czasowych, który uwzględniac będzie nagłe zmiany klimatu zasugerowane w literaturze (**I.B.2**).

Badania własne

Zdecydowałem, iż w pracy przeprowadzę analizę dla 3 lokalizacji o zróżnicowanych warunkach klimatycznych, leżących w europejskim transekcie klimatycznym, po jednej z Hiszpanii, Niemiec i Finlandii. 31-letnie szeregi czasowe temperatury powietrza, opadu oraz natężenia promieniowania słonecznego z okresu 1980-2010 zostały najpierw poddane procesowi usuwania sezonowości STL, a następnie podzielone na dwa podzbiory: pierwszy zawierający dane z okresu od 1980 do 2001 roku (8035 punktów empirycznych), drugi z okresu 2002–2010 (3287 punktów empirycznych). Elementy meteorologiczne rejestrowane były we wszystkich lokalizacjach przy pomocy porównywalnej aparatury o standardzie pomiaru zgodnym z rekomendacjami WMO. W celu zbadania i porównania właściwości skalowania szeregów czasowych wielkości meteorologicznych zastosowałem metodę MF-DFA, określając zarówno podstawowe parametry charakteryzujące widmo multifraktalne, jak i źródło multifraktalności, w obydwu podzbiórach.

Wyniki, podsumowanie i wnioski

Analizy źródła multifraktalności wykonane dla obydwu podzbiorów potwierdziły ważny wniosek płynący z pierwszej pracy (**I.B.1**). Multifraktalność szeregów czasowych temperatury powietrza i natężenia promieniowania słonecznego, niezależnie od analizowanego podzbioru, wynika głównie z obecności korelacji długozasięgowych w ich strukturze, a szerokość funkcji gęstości prawdopodobieństwa odpowiada jedynie w niewielkim stopniu za ich multifraktalność. Z kolei źródło multifraktalności szeregów czasowych opadów jest dwojakie i bierze się zarówno z ogonów w rozkładzie funkcji gęstości prawdopodobieństwa, jak i (choć w mniejszym stopniu) z obecności korelacji długozasięgowych w ich strukturze. Analiza porównawcza podstawowych parametrów charakteryzujących widmo multifraktalne dla podokresów wskazuje największe ich zróżnicowanie dla opadu. Uzyskane wyniki potwierdzają, że opad może być elementem meteorologicznym, którego własności skalowania są bardziej

wrażliwe na zmiany w dynamice klimatu, co ma związek z silniejszym niż w innych analizowanych parametrach meteorologicznych wpływem szerokości funkcji gęstości prawdopodobieństwa na jego multifraktalność. Ponadto zaobserwowałem silne zróżnicowanie przestrzenne parametrów opisujących widmo, co potwierdziło, iż metoda MF-DFA może być użyteczna do oceny różnic w dynamice procesów meteorologicznych dla lokalizacji o zróżnicowanych warunkach klimatycznych. W analizie porównawczej wykonanej dla obydwu podokresów zaznacza się wyraźny trend zmian, niezależnie od lokalizacji czy badanego elementu meteorologicznego. Zaobserwowałem, że w okresie po raportowanej nagłej zmianie klimatu: wartość siły spektrum w jego maksimum α_0 nieznacznie wzrosła, co sugeruje trochę mniejszą regularność przebiegu szeregów czasowych; asymetria a_s pozostawała dodatnia (widmo prawoskośne), ale jej wartości były mniejsze, co sugeruje wzrastający udział struktur na poziomie dużych amplitud fluktuacji, czyli częstsze występowanie zdarzeń ekstremalnych; szerokość widma w , a tym samym złożoność struktury sygnału, malała. Obserwowane zmiany w dynamice dla drugiego podokresu są zdecydowanie bardziej wyraźne w lokalizacjach klimatycznie skrajnych (Finlandia oraz Hiszpania), niż w lokalizacji o klimacie umiarkowanym (Niemcy). Nieznaczne zmiany parametrów charakteryzujących widmo multifraktalne dla lokalizacji niemieckiej sugerują większą odporność klimatu umiarkowanego na ewolucję w dynamice procesów zachodzących w tej strefie klimatycznej.

Publikacja I.B.3 pt. „Wpływ agregacji czasowej na właściwości multifraktalne agrometeorologicznych szeregów czasowych” („Temporal scale influence on multifractal properties of agrometeorological time series”)

Problem badawczy

Prowadząc badania własności skalowania szeregów czasowych różnych elementów meteorologicznych zarejestrowanych w lokalizacjach charakteryzujących się odmiennymi warunkami klimatycznymi, zacząłem zastanawiać się, jakie dodatkowe czynniki, poza rejestracją danych prowadzoną w różnych lokalizacjach za pomocą aparatury o różniącym się standardzie pomiaru (np. pomiar temperatury powietrza czy prędkości wiatru prowadzony na innej wysokości nad poziomem gruntu), mogą wpływać na uzyskany wynik i być powodem, iż danych literaturowych pochodzących z różnych publikacji nie da się ze sobą porównywać. Czynnikiem, który zwrócił moją uwagę przy przeglądaniu literatury specjalistycznej w pierwszej kolejności była różna skala czasowa prowadzonych pomiarów - na przykład w dwóch publikacjach różnego autorstwa, wydanych w 2013 roku i dotyczących właściwości multifraktalnych szeregów czasowych opadów, analizowano szeregi o rozdzielczościach: minutowej (Yonghe i in., 2013) oraz 8-minutowej (Rodríguez i in., 2013). W opracowaniach naukowych dotyczących analizy multifraktalnej nie znalazłem jednak doniesienia, w którym podjęto próbę określenia, w jaki sposób przy zmianie skali czasowej danych agrometeorologicznych zachowywane są lokalne trendy czy korelacje długozasięgowe. Zauważona luka w wiedzy była motywacją do przeprowadzenia badań czy, i ewentualnie w jakim stopniu, agregacja czasowa wpływa na właściwości skalowania różnych szeregów wielkości agrometeorologicznych. Dodatkową motywacją do przeprowadzenia badań było to, iż różne modele wzrostu, rozwoju i plonowania roślin, modelując procesy zachodzące w układzie gleba-roślina-atmosfera, posłu-

gują się rozmaita skalą czasową (choć najczęściej - godzinową albo dobową). Tym samym wymagają jako danych wejściowych szeregów meteorologicznych o zróżnicowanej rozdzielczości czasowej. Najczęściej wymagana w modelach czasowa rozdzielczość jest inna niż ta, z którą dane były rejestrowane, co powoduje potrzebę zastosowania agregacji. Dlatego też, w trzeciej pracy z cyklu (**I.B.3**) przeprowadziłem badania dotyczące wpływu agregacji czasowej danych meteorologicznych na ich właściwości skalowania.

Badania własne

Obiektem, na którym przeprowadzono badania, były 14-letnie szeregi czasowe 4 wielkości agrometeorologicznych: temperatury powietrza, opadu, prędkości wiatru oraz temperatury gleby. Dane eksperymentalne były rejestrowane w okresie od 8 maja 2001 do 11 listopada 2014 roku z rozdzielczością godzinową na stacji meteorologicznej zlokalizowanej na terenie Instytutu Agrofizyki PAN w Lublinie, a następnie poddane agregacji do wartości dobowych wykorzystując uśrednianie (temperatura powietrza i gleby oraz prędkość wiatru) lub sumowanie (opad). Zarówno dane godzinowe, jak i dobowe, zostały poddane procedurze usunięcia sezonowości, a następnie analizie multifraktalnej MF-DFA. Określone zostało także źródło multifraktalności analizowanych szeregów czasowych.

Istotną kwestią w analizie multifraktalnej jest poprawny wybór zakresu rozmiarów nie nakładających się segmentów s , ponieważ uogólnione funkcje $F_q(s)$, a tym samym właściwości skalowania, mogą zależeć od tego wyboru. W literaturze nie odnajdziemy jednoznacznego przepisu określającego jak prawidłowo dobrać s_{min} i s_{max} , jednak istnieją pewne sugestie pozwalające uniknąć niepoprawnego cechowania. I tak, Kantelhardt i in. (2002) sugeruje, że w metodzie MF-DFA maksymalny rozmiar segmentu powinien być nie większy niż $N/4$, gdzie N to długość analizowanej serii, a minimalny równy $m+2$, gdzie m to stopień wielomianu używanego do odtrendowania analizowanych danych. Wang i in. (2016) zauważył, że w przypadku danych o większej rozdzielczości czasowej niż dobową, dolny zakres s_{min} powinien być dłuższy niż jeden dzień, ponieważ wybór mniejszych wartości s_{min} powoduje nieuzasadniony, nagły spadek wartości wykładników skalowania, tym samym wprowadzając duży błąd ich oszacowania. W przeprowadzonych badaniach zdecydowałem się zastosować taki zakres segmentów dla danych godzinowych i dobowych, by odpowiadał on temu samemu okresowi i był zgodny z powyższymi rekomendacjami. Dlatego też przyjąłem, że w analizie danych dobowych $s_{min}=5$ i $s_{max}=1200$, a danych godzinowych $s_{min}=5 \times 24=120$, a $s_{max}=1200 \times 24=28800$.

Wyniki, podsumowanie i wnioski

Niezależnie od skali czasowej analizowanych szeregów, źródłem multifraktalności szeregów czasowych opadów były zarówno korelacje długozasięgowe obecne w ich strukturze, jak i szerokość rozkładu funkcji gęstości prawdopodobieństwa. Tym samym widmo multifraktalne szeregu czasowego opadów różni się od widm innych wielkości agrometeorologicznych, za których multifraktalność odpowiedzialne są głównie korelacje długozasięgowe. Wniosek ten, otrzymany w poprzednich analizach (**I.B.1** oraz **I.B.2**), został więc rozszerzony o niezmienniczość ze względu na analizowaną skalę czasową danych.

Stwierdziłem również, iż czasowa agregacja badanych szeregów wyraźnie wpływa na ich właściwości skalowania, jednak wielkość tego wpływu jest zależna od elementu meteorologicznego. Wpływ agregacji jest najbardziej widoczny dla szeregu czasowego opadu i temperatury gleby, a najmniej zauważalny dla szeregu czasowego temperatury powietrza i prędkości wiatru. Agregacja do wartości dobowych powoduje, iż spektra w ogólności stają się prawoskośne (wartość skośności zmienia się z ujemnej na dodatnią lub ma wyższą wartość dodatnią), czyli charakteryzują się strukturą multifraktalną, która jest niewrażliwa na lokalne fluktuacje o dużych amplitudach. Jedynie dla opadu uzyskałem zmianę asymetrii z prawoskośnej na lewoskośną, co sugeruje częstsze występowanie zdarzeń ekstremalnych. Ma to najprawdopodobniej związek ze sposobem agregacji danych do wartości dobowych, który w przypadku opadu polega na sumowaniu wartości godzinowych. Po agregacji danych szerokość widma, a tym samym siła dynamiki multifraktalnej, jest większa dla temperatury powietrza i prędkości wiatru, a mniejsza dla opadu i temperatury gleby. Ponadto, zaobserwowałem, że agregacja silnie wpłynęła na źródła multifraktalności, zmniejszając wkład pochodzący zarówno od korelacji długozasięgowych, jak i szerokości funkcji gęstości prawdopodobieństwa, w szczególności dla fluktuacji o małych amplitudach. Z otrzymanego przeze mnie wyniku płynie wniosek, iż agregacja do wartości dobowych skutkuje utratą niektórych unikalnych multifraktalnych właściwości obecnych w szeregach czasowych rejestrowanych z rozdzielczością godzinową, co oznacza, iż agregacja czasowa danych może być źródłem nieoczekiwanie dużych błędów w modelach ogólnej cyrkulacji (Global Climate Model, GCM) czy modelach wzrostu, rozwoju i plonowania roślin oraz innych zastosowaniach posługujących się zróżnicowaną skalą czasową danych.

Publikacja I.B.4 pt. „Czasowe własności meteorologicznych szeregów czasowych zagregowanych przestrzennie” („Temporal properties of spatially aggregated meteorological time series”)

Problem badawczy

Czwarta praca z cyklu poświęcona została badaniom wpływu agregacji przestrzennej danych meteorologicznych na własności skalowania tych danych. W celu uwzględnienia skomplikowanych interakcji zachodzących w systemach, a tym samym uogólnienia otrzymywanych wniosków oraz otrzymania reprezentatywnych wyników, coraz częściej stosuje się modelowanie w dużych skalach przestrzennych. Podejście takie jest już od pewnego czasu powszechne w zagadnieniach klimatycznych, takich jak prognoza pogody czy w badaniach dotyczących zmian klimatu. Modele zmian klimatu tworzone są na podstawie wiedzy dotyczącej praw fizycznych rządzących cyrkulacją mas powietrza oraz mechaniką płynów w skali globalnej i starają się opisywać możliwie wiernie przebieg zjawisk w dużej skali, jednocześnie parametryzując procesy podskalowe, czyli zachodzące na obszarach mniejszych niż rozmiar siatki modelu. Również w badaniach modelowych plonowania roślin obserwuje się częstsze próby przeprowadzania analiz w skalach przestrzennych obejmujących region, kraj, a nawet i kontynent, ponieważ tylko w tych skalach uwzględnić można interakcje pomiędzy produkcją rolną, ekonomią, a polityką rolną tworzoną przez decydentów. Większość modeli wzrostu, rozwoju i plonowania roślin została opracowana tak, by być uruchamiana i dawać wyniki w skali jednego pola. Rozszerzenie skali przestrzennej wykorzystującej modele tego typu polega na wielokrotnym ich uruchomieniu dla każdego punktu siatki numerycznej, dla którego określone zostały

dane wejściowe (np. dane meteorologiczne). Istnieją również modele pracujące w większej skali niż skala pola uprawnego. Zastosowanie tego typu modeli, czy modeli zmian klimatu, do przeprowadzenia badań w dużych skalach przestrzennych, wymaga najczęściej danych wejściowych o niewielkiej rozdzielczości przestrzennej, która determinowana jest przez wielkość siatki użytej w konkretnym modelu. Bezpośrednie pomiary w wymaganych skalach przestrzennych uzyskać można, na przykład, z wykorzystaniem metod teledetekcyjnych. Zwykle jednak dane o żądanej rozdzielczości przestrzennej uzyskuje się agregując dane o innej rozdzielczości, jak to jest choćby w przypadku szeregów czasowych wielkości meteorologicznych, których pomiaru nie dokonuje się w skali regionu czy globu, a wartości regionalne (globalne) uzyskuje się uśredniając dane zarejestrowane w znacznie wyższych rozdzielczości przestrzennych. Wiadomo, że proces przestrzennego uśredniania wpływa na strukturę szeregu czasowego, powodując na przykład wygładzanie amplitud oscylacji obecnych w strukturze sygnału, czy usuwanie z szeregu wartości ekstremalnych. Oznacza to, że agregacja przestrzenna wpływa na czasowe właściwości meteorologicznych szeregów czasowych. O ile rozważania dotyczące interakcji czasowo-przestrzennych w szeregach czasowych wielkości meteorologicznych były już przeprowadzane (Lovejoy i in., 2012; Pathirana i Herath, 2002), to wpływ agregacji przestrzennej do niższych rozdzielczości na zmiany właściwości multifraktalnych był do tej pory niezbadany. Brak badań tego typu stał się więc motywacją do przeprowadzenia analizy porównującej właściwości skalowania szeregów różnych wielkości agrometeorologicznych otrzymanych w wyniku zmniejszania ich rozdzielczości przestrzennej.

Badania własne

Wpływ agregacji przestrzennej danych na czasowe właściwości szeregów czasowych wybranych wielkości meteorologicznych zbadano dla obszaru Nadrenii Północnej-Westfalii, leżącej w zachodniej części Niemiec. Region ten zajmuje powierzchnię około 34100 km² i charakteryzuje się niejednorodną topografią. Analizie poddałem dobowe wartości takich wielkości meteorologicznych jak opad, wilgotność powietrza, natężenie promieniowania słonecznego, ewapotranspiracja, minimalna, maksymalna i średnia temperatura powietrza oraz prędkość wiatru. Dane rejestrowane były na 280 stacjach klimatycznych niemieckiej służby meteorologicznej w latach 1982-2011. Dane zostały przetransformowane do postaci regularnej siatki o rozdzielczości 1km zgodnie z procedurą opisaną przez Zhao i in. (2015), a następnie zagregowane przestrzennie do siatek o rozdzielczościach 1, 10, 25, 50 i 100 km. Agregacja do zadanej skali przestrzennej została wykonana osobno dla każdego punktu empirycznego w szeregach czasowych. Szeregi czasowe wybranych wielkości meteorologicznych, posiadające różną skalę przestrzenną agregacji, zostały następnie poddane procedurze usunięcia sezonowości STL oraz analizie multifraktalnej MF-DFA. Określone zostało także źródło multifraktalności analizowanych szeregów czasowych.

Wyniki, podsumowanie i wnioski

Wyniki analizy multifraktalnej dla skali 1 km stanowiły referencję w stosunku do wyników uzyskanych dla pozostałych, niższych rozdzielczości przestrzennych. Wpływ efektu agregacji przestrzennej na czasowe właściwości szeregów wielkości meteorologicznych oce-

niany był, przede wszystkim, poprzez analizę zmienności parametrów α_0 , a_s i w charakteryzujących widmo multifraktalne (rys. 2). Wykazała ona, iż parametry multifraktalne cechują się znacznym zróżnicowaniem, zarówno przestrzennym, jak i pomiędzy analizowanymi wielkościami. Zmienność przestrzenna parametrów α_0 , a_s i w była związana, przynajmniej w niektórych przypadkach, z orografią badanego obszaru. W rzeczywistości orografia wpływa w znacznej mierze na dynamikę procesów meteorologicznych, co odzwierciedla się w niższych temperaturach i większych opadach dla obszarów wyżej położonych. Orografia została częściowo odzwierciedlona w przestrzennym rozkładzie parametrów multifraktalnych, na przykład największe wartości szerokości multifraktalnej otrzymano dla obszaru wzgórz położonych w centralnej i wschodniej jego części, co oznacza, że obszary położone najwyżej mają bardziej rozwiniętą multifraktalność, niż te leżące poniżej. Asymetria a_s dla większości analizowanych wielkości meteorologicznych okazała się być prawoskośna. Jedynie szeregi czasowe opadu charakteryzowały się zarówno prawo, jak i lewoskośnymi spektrami, co oznacza, że dla niektórych obszarów w strukturze szeregów tej wielkości częściej występowały zdarzenia ekstremalne. Jednocześnie zakres zmienności parametrów multifraktalnych α_0 , a_s i w był znacznie większy dla opadu, niż dla innych analizowanych wielkości meteorologicznych. Agregacja przestrzenna szeregów czasowych do niższych rozdzielczości zachowywała, w znacznej mierze, wzory widoczne w przestrzennym rozkładzie parametrów multifraktalnych. Zmienność ich wartości była jednak znacznie mniejsza wraz z malejącą rozdzielczością. W rozdzielczości 100 km największą zmiennością α_0 charakteryzował się opad, z kolei dla a_s i w to natężenie promieniowania słonecznego i temperatury zachowały największą zmienność przestrzenną. Zarówno duża zmienność przestrzenna parametrów multifraktalnych opadu, jak i znacznie większe ograniczenie tej zmienności po agregacji niż dla innych elementów meteorologicznych, oznaczają, iż czasowe właściwości szeregów opadu są bardziej wrażliwe na efekty związane z agregacją przestrzenną. Dodatkowo przeprowadziłem analizę źródeł multifraktalności szeregów czasowych w różnych skalach przestrzennych. Okazało się, iż dla większości analizowanych wielkości meteorologicznych przestrzenna agregacja wpływa na obydwa źródła multifraktalności w nieznacznym stopniu. Jedynie dla szeregów czasowych opadu wpływ szerokości funkcji gęstości prawdopodobieństwa na multifraktalność jest zauważalnie mniejszy, w szczególności dla fluktuacji o małych amplitudach.

Agregacja przestrzenna danych skutkuje podobnymi efektami jak agregacja czasowa. Obserwowane po agregacji zmiany w strukturze przestrzennej parametrów multifraktalnych i ograniczenie zakresu ich zmienności wskazują, że przestrzenna agregacja szeregów czasowych wielkości meteorologicznych ma wpływ na ich własności skalowania. Stopień zmian właściwości skalowania powinno się uwzględniać w modelach opracowanych dla dużej skali przestrzennej, wykorzystujących dane agregowane.

Publikacja I.B.5 pt. „Charakterystyka multifraktalna i porównanie szeregów czasowych wielkości meteorologicznych pochodzących z dwóch stref klimatycznych” („Multifractal characterization and comparison of meteorological time series from two climatic zones”)

Problem badawczy

Uczestnicząc w realizacji dwóch polsko-bułgarskich projektów badawczych w ramach współpracy bilateralnej pomiędzy Polską a Bułgarską Akademią Nauk (**II.I.2** oraz **II.I.6**), nawiązałem współpracę z prof. dr hab. Valentinem Kazandijevem. W jej ramach przygotowaliśmy kolejny projekt bilateralny na lata 2019-2021 pt. „Adaptacja do zmian klimatu jako czynnik determinujący zrównoważoną produkcję rolniczą w Polsce i Bułgarii”. Założeniem przygotowywanego projektu jest przeprowadzenie eksperymentu modelowego w celu określenia, jak zmiany klimatyczne wpłyną na produkcję roślinną w Polsce i Bułgarii oraz jakie zabiegi adaptacyjne zaproponować, aby przeciwdziałać wpływowi niekorzystnemu. Eksperyment modelowy miał być przeprowadzony dla dwóch lokalizacji w Polsce i dwóch w Bułgarii. Aby uzyskać informacje o ewolucji w dynamice procesów meteorologicznych w rejonach wybranych do przeprowadzenia modelowania, przeprowadziliśmy badania właściwości skalowania meteorologicznych szeregów czasowych pochodzących z tych lokalizacji (**I.B.5**). Przeprowadzona przeze mnie analiza była analogiczna do tej przedstawionej w publikacji **I.B.2**.

Badania własne

Analiza, wyniki której zaprezentowane są w piątej publikacji z cyklu, przeprowadzona została na szeregach czasowych wielkości agrometeorologicznych pochodzących z 3 stacji meteorologicznych położonych wśród pól uprawnych (Grabów w Polsce oraz Knezha i Chirpan w Bułgarii) i 1 umiejscowionej co prawda w obrębie zabudowy miejskiej (Lublin), ale w relatywnie niedużej odległości od pól uprawnych. Na wszystkich stacjach elementy meteorologiczne rejestrowane były przy pomocy porównywalnej aparatury o ustalonym standardzie (WMO) pomiaru. Lokalizacje polskie, według klasyfikacji klimatu Köppena-Geigera, charakteryzują się identycznymi warunkami klimatycznymi. Bułgarskie natomiast leżą, według tej samej klasyfikacji, w różnych strefach klimatycznych i odróżniają się typem klimatu od lokalizacji polskich. Badano 31-letnie szeregi czasowych temperatury powietrza, opadu, wilgotności powietrza oraz prędkości wiatru z okresu 1980-2010. Zastosowanie metody STL pozwoliło na usunięcie sezonowości z ich przebiegów. W kolejnym kroku podzieliłem te szeregi na dwa podzbiory, pierwszy zawierający dane z okresu od 1980 do 2001 roku (8035 punktów empirycznych), oraz drugi, z danymi z okresu 2002–2010 (3287 punktów empirycznych). Podział ten uwzględniał raportowane w literaturze nagłe zmiany w wielkościach charakteryzujących klimat (Swanson i Tsonis, 2009; Huntingford i in., 2013). W celu zbadania i porównania właściwości skalowania szeregów czasowych wielkości meteorologicznych zastosowałem metodę MF-DFA, określając w obydwu podzbiorach zarówno podstawowe parametry charakteryzujące widmo multifraktalne, jak i źródło multifraktalności.

Wyniki, podsumowanie i wnioski

Otrzymane wyniki potwierdzają wnioski płynące z publikacji **I.B.2**. Badane wielkości meteorologiczne charakteryzują się swoistą dynamiką czasowo-przestrzenną, która wykazuje własności samopodobieństwa. Jest to inherentna cecha szeregów czasowych wielkości meteorologicznych, gdyż multifraktalność wykazywały wszystkie elementy meteorologiczne, niez-

leżnie od miejsca ich pomiaru, czy okresu poddanego analizie. Źródłem multifraktalności takich wielkości jak wilgotność czy temperatura powietrza, są w przeważającej mierze korelacje długozasięgowe. Są one także głównym źródłem multifraktalności szeregów prędkości wiatru, ale ich wkład nie jest tak dominujący, jak w przypadku wymienionych wyżej elementów meteorologicznych. Szeregi czasowe opadu posiadają odmienny charakter multifraktalności od innych analizowanych elementów meteorologicznych, gdyż za ich multifraktalność odpowiedzialne są obydwie źródła - zarówno szerokość funkcji gęstości prawdopodobieństwa, jak i korelacje długozasięgowe.

Dodatkową informację rozszerzającą konkluzje płynące z poprzednich publikacji cyklu (**I.B.1**, **I.B.2**, **I.B.3** oraz **I.B.4**) ujawniła analiza parametrów charakteryzujących widmo multifraktalne. Parametry te charakteryzowały się zbliżonymi wartościami dla szeregów zarejestrowanych w lokalizacjach pochodzących z tego samego kraju (czyli leżących w relatywnie niewielkich odległościach od siebie), z kolei większe zróżnicowanie ich wartości zaobserwować można było pomiędzy lokalizacjami bardziej odległymi przestrzennie (polskimi a bułgarskimi). Mimo zaobserwowanej ogólnej tendencji, lokalne charakterystyki klimatyczne również manifestowały swój wpływ na wartości α_0 , α_s i w , co przejawia się nieznacznie większym zróżnicowaniem tych wielkości dla stacji bułgarskich, cechujących się różnymi typami klimatu, niż dla stacji polskich. Stanowi to przesłankę sugerującą, iż multifraktalna analiza odtrendowanych fluktuacji może być odpowiednią metodą do jakościowego, a nawet, w wyniku oszacowania wartości α_0 , α_s oraz w , ilościowego scharakteryzowania przestrzennej zmienności dynamiki procesów rządzących atmosferą.

Przeprowadzona analiza właściwości skalowania szeregów czasowych podzielonych na dwa podzbiory potwierdza wnioski z poprzednich prac (**I.B.1** i **I.B.2**). Metoda MF-DFA jest w stanie wykryć zmiany zachodzące w dynamice klimatu. Parametr asymetrii w podzbiore późniejszym chronologicznie ma tendencję do przyjmowania wartości mniej dodatnich (albo nawet ujemnych), co wyraźnie wskazuje, że obecnie obserwowana dynamika zjawisk pogodowych charakteryzuje się występowaniem większej ilości zdarzeń ekstremalnych (albo zdarzenia te zaczynają dominować w strukturze sygnału).

Publikacja **I.B.6** pt. „Prognozowanie dobowych wartości szeregów czasowych wielkości meteorologicznych przy użyciu metody ARIMA oraz modeli regresyjnych” („Forecasting daily meteorological time series using ARIMA and regression models”)

Problem badawczy

Szeregi czasowe wielkości meteorologicznych wykorzystywane są, między innymi, jako dane wejściowe w modelach wzrostu, rozwoju i plonowania roślin. Aby przeprowadzić analizę dotyczącą zmian w produkcji rolnej w latach przyszłych, zarówno tych najbliższych, jak i bardziej odległych, niezbędne są prognozy przebiegów szeregów czasowych wielkości agrometeorologicznych. Prognozy przebiegów szeregów czasowych takich wielkości są zwykle obarczone dużym błędem estymacji, co wynika ze złożoności procesów opisujących układ gleba-roślina-atmosfera, oraz z dynamicznego charakteru atmosfery. Dodatkowo szeregi te posiadają złożoną budowę, charakteryzującą się obecnością korelacji długozasięgowych w ich

strukturze (publikacje od **I.B.1 do I.B.5**). Struktura ta powinna być zachowana w prognozowanej serii. Istnieje wiele metod predykcji przebiegów elementów meteorologicznych, często jednak ich zdolność do tworzenia długoterminowych prognoz jest ograniczona. Dlatego też stale tworzone i rozwijane są metody analizy szeregów czasowych i przetwarzania danych historycznych w celu opracowania skutecznego modelu predykcyjnego. W kontekście zmian klimatycznych obserwowanych w ostatnich latach, objawiających się tendencją do wzrostu średnich wartości temperatur i malejącą intensywnością opadu, szczególnie duże znaczenie wydaje się mieć predykcja przyszłych przebiegów szeregów czasowych właśnie tych wielkości.

Celem szóstej publikacji z cyklu (**I.B.6**) było więc opracowanie takich metod długoterminowej prognozy dobowych wartości szeregów meteorologicznych temperatury powietrza i opadu, które nie tylko charakteryzowałyby się predykcją o dokładności umożliwiającej ich stosowanie w modelowaniu produkcji roślinnej, ale które jednocześnie nie zmieniałyby własności skalowania danego elementu meteorologicznego.

Badania własne

Zastosowane w pracy metody: zintegrowanego sezonowego modelu autoregresyjnego ze średnią ruchomą SARIMA, zintegrowanego modelu autoregresyjnego ze średnią ruchomą z rezyduami zmodyfikowanymi Fourierowsko ARIMAF, wielomianowego modelu regresyjnego RMP oraz modelu regresyjnego z szeregiem Fouriera RPF, do stworzenia działającego modelu prognostycznego wymagają nie tylko zestawu danych uczących, ale przede wszystkim - sparametryzowania modelu dla tego zestawu. Zróznicowanie procesów klimatycznych zachodzących w danej lokalizacji sprawia, iż nie tylko rodzaj użytej metody może nie oddawać złożoności procesów mających wpływ na strukturę danego szeregu meteorologicznego, ale i parametryzacja wykonana dla danego punktu w przestrzeni, czy obszaru, może nie być odpowiednia dla punktu (czy obszaru) charakteryzującego się innymi warunkami klimatycznymi. W badaniach wykorzystałem dane meteorologiczne pochodzące z 4 lokalizacji w Europie o odmiennych warunkach klimatycznych, co pozwoliło na sprawdzenie, czy istnieje model uniwersalny (zarówno jeżeli chodzi o rodzaj metody, jak i parametry modelu), zastosowanie którego skutkuje dużą zgodnością predykcji we wszystkich uwzględnionych lokalizacjach. Do przeprowadzenia badań posłużyły wartości dobowe 31-letnich szeregów czasowych temperatury powietrza oraz opadu zarejestrowane w okresie od 1 stycznia 1980 do 31 grudnia 2010 (w sumie dla 11322 dni) na stacjach meteorologicznych w Lleidzie w Hiszpanii, Dikopshof w Niemczech, Lublinie w Polsce oraz Jokioinen w Finlandii. Zarówno temperatura powietrza, jak i opad, rejestrowane były we wszystkich lokalizacjach przy pomocy porównywalnej aparatury o tym samym standardzie pomiaru. Szeregi czasowe zostały podzielone na dwie części. Pierwszy z nich posłużył jako zestaw uczący i zawierał dane z okresu od 1 stycznia 1980 do 31 grudnia 2004. W oparciu o te dane dokonano parametryzacji modeli predykcyjnych temperatury i opadu SARIMA, ARIMAF, RMP oraz RMF. Przeprowadzone analizy funkcji autokorelacji oraz częściowej autokorelacji modelowanych szeregów czasowych, jak i ich własności skalowania, pozwoliły na wybranie takich parametryzacji w stosowanych metodach, które nie wpływały na strukturę korelacji długozasięgowych. Dane z okresu od 1 stycznia 2005 do 31 grudnia 2010 posłużyły jako zestaw testowy do oceny mocy predykcyjnej modeli. Otrzymane prognozy oceniano

za pomocą standardowych miar trafności prognoz: średniego błędu absolutnego (MAE), pierwiastka błędu średniokwadratowego (RMSE) i średniego absolutnego błędu skalowanego (MASE).

Wyniki, podsumowanie i wnioski

Przeprowadziłem analizy zarówno funkcji autokorelacji oraz częściowej autokorelacji modelowanych szeregów czasowych, jak i ich własności skalowania, dla 4 metod stosowanych w publikacji. Uzyskane wyniki wskazują, iż w przypadku każdej metody możliwe jest wybranie takich zakresów parametrów, by prognozowane przebiegi dobowe temperatury powietrza i opadu zachowywały inherentne cechy występujące w strukturze badanych szeregów. Ocena zdolności predykcyjnej otrzymanych długoterminowych prognoz dobowych wartości wskazuje, iż w przypadku temperatury powietrza, metoda ARIMAF daje najniższe wartości miar trafności prognoz, niezależnie od analizowanej lokalizacji. Nie istnieje jednak jedna, uniwersalna, parametryzacja tej metody, i dla każdej lokalizacji (warunków klimatycznych) procedurę parametryzacji należy powtórzyć. W przypadku opadów nie udało się uzyskać równie ogólnego wyniku, jak dla temperatury powietrza, ponieważ zarówno wybór odpowiedniej metody statystycznej, jak i jej parametryzacji, dającej najniższe wartości standardowych miar trafności prognoz, zależy od lokalizacji (strefy klimatycznej), z której pochodzą szeregi meteorologiczne tej wielkości.

Podstawową zaletą zaproponowanych metod jest to, iż tworzą one prognozę długoterminową jedynie w oparciu o analizę danych historycznych wielkości prognozowanej. Stosunkowo duże błędy prognozy dobowych wartości zdają się ograniczać zakres stosowalności prognoz uzyskanych zaproponowanymi metodami. Jednak 6-letnia predykcja trafnie oddaje przebieg danych eksperymentalnych, systematycznie zawyżając i zaniżając kolejne wartości szeregu. Ponieważ w modelach produkcji rolnej koncepcja rozwoju roślin jest matematycznie realizowana za pomocą sumy temperatur efektywnych, to różnokierunkowość błędu prognozowania szeregów temperatury powietrza może skutkować jego kompensacją i nie wpływać znacząco na wynik. Dlatego też zaproponowana metoda wydaje się mieć potencjał użyteczny w modelowych badaniach zmian, jakie mogą zajść w produkcji roślinnej w przyszłych latach.

Publikacja I.B.7 pt. „Adaptacyjne powierzchnie odpowiedzi w odniesieniu do zabiegów uprawowych dla pszenicy uwzględniające modyfikacje klimatu i koncentracji CO₂ w agroekosystemie śródziemnomorskim” („Adaptation response surfaces for managing wheat under perturbed climate and CO₂ in a Mediterranean environment”)

Problem badawczy

Zmiany klimatyczne wywierają ogromny wpływ na rolnictwo, w globalnej skali stanowiąc istotne zagrożenie dla produkcji żywności. Obserwacje klimatyczne prowadzone w ostatnich dekadach wskazują na istnienie trendu wzrostowego w średnich wartościach temperatur oraz malejącego w intensywności opadu. Symulacje zmian klimatycznych przeprowadzone z zastosowaniem modeli globalnej cyrkulacji sugerują, iż obserwowane tendencje się nie zmienią, skutkując zmniejszeniem wartości sum rocznych opadów o ok. -15% i wzrostem średniej rocznej temperatury o ok. +5°C na koniec tego stulecia w stosunku do wartości średnich

z ostatniej dekady. Oznacza to, iż wpływ zmian klimatycznych objawiał się będzie zwiększonymi stresami suszy glebowej i cieplnym, które zaliczane są do najważniejszych czynników ograniczających plonowanie roślin uprawnych. Szacuje się, iż pozytywny dla roślin aspekt zwiększonej koncentracji CO₂ w atmosferze nie będzie w stanie równoważyć stresu cieplnego, skutkując redukcją uzyskiwanych plonów. Warunkiem koniecznym do zapewnienia rosnącej populacji światowej powszechnego dostępu do żywności będzie intensyfikacja produkcji rolnej. Można ją uzyskać poprzez zwiększenie areału upraw oraz podniesienie efektywności produkcji rolnej przez stosowanie odmian o fenologii lepiej dopasowanej do lokalnych warunków klimatycznych, bardziej odpornych na stres i dających wyższy plon. Efektywności produkcji rolnej można także podnieść, stosując zabiegi uprawowe. W niektórych strefach klimatycznych pojedynczy zabieg uprawowy (opcja adaptacyjna) może nie być wystarczający, aby przeciwdziałać skutkom postępujących zmian klimatycznych. W rzeczywistości, wynikiem stosowania kombinacji opcji adaptacyjnych, jest rezultat, będący kompromisem interakcji pomiędzy modyfikacjami wprowadzanymi poprzez poszczególne adaptacje. Dodatkowo, rezultat ten jest zależny od lokalnych warunków środowiskowych danego pola, czy obszaru. Pojawia się więc wyraźna potrzeba przeprowadzenia analiz wpływu kombinacji różnych opcji adaptacyjnych na plonowanie roślin w warunkach zmian klimatycznych dla zróżnicowanych lokalizacji.

Eksperymentalna weryfikacja wpływu kombinacji różnych opcji adaptacyjnych na plonowanie roślin w warunkach zmian klimatycznych wymagałyby przeprowadzenia wieloletnich i pracochłonnych doświadczeń. Do przeprowadzenia tego typu badań często stosuje się więc modele wzrostu, rozwoju i plonowania roślin. Pozwalają one na uwzględnienie zróżnicowanych strategii stosowania zabiegów uprawowych i uzyskanie informacji o zmianie wielkości plonu powodowanej przez dany zabieg dla lokalnych warunków klimatycznych. Do działania potrzebują jednak szeregów czasowych wielkości meteorologicznych. Dlatego też, aby przeprowadzić badania wpływu zabiegów adaptacyjnych na plon w kontekście zmian klimatycznych, należy przygotować długoterminowe prognozy wartości dobowych szeregów oddających przyszłe warunki klimatyczne. Prognozowane przebiegi powinny zachowywać własności skalowania danego elementu meteorologicznego.

W pracy **I.B.7** przeprowadzono analizę wpływu zabiegów adaptacyjnych na zmiany w poziomie produkcji roślinnej w warunkach zmieniającego się klimatu z wykorzystaniem szeregów zachowujących skalowanie w celu określenia, które kombinacje zabiegów adaptacyjnych skutkują maksymalizacją uzyskiwanego plonu.

Badania własne

Badania przeprowadzono dla warunków klimatycznych panujących w północno-wschodniej części Hiszpanii. Analiza spektrum scenariuszy klimatu dla okresu 2020-2070 wskazała, że możliwe, prognozowane przez te scenariusze, zakresy zmian charakterystyk opadu i temperatury dla okresu 2020-2070 w badanej lokalizacji zawierają się w granicach od -1°C do $+7^{\circ}\text{C}$ średniej dobowej wartości temperatury powietrza, oraz od -40% do $+30\%$ intensywności opadów, w stosunku do warunków aktualnych. Przeprowadzona analiza własności skalowania szeregów czasowych wielkości agrometeorologicznych pozwoliła na zaproponowanie takiej metody otrzymania wartości dobowych szeregów meteorologicznych temperatury

powietrza i opadu oddającej przyszłe warunki klimatyczne dla tej lokalizacji, która te własności zachowuje. Do przeprowadzenia części modelowej badań korzystałem z modelu WOFOST i modelowałem plon pszenicy. Do kalibracji modelu wykorzystano obserwacje fenologii odmiany Soissons pszenicy ozimej (daty kwitnienia i dojrzałości) oraz wielkość plonu i biomasy części nadziemnej zarejestrowane w latach 2003-2006 na polach uprawnych w Agramunt i Gimennells, znajdujących się w okolicy Lleidy. Było to powodem, dlaczego w badaniach uwzględniono właściwości fizykochemiczne dwóch rzeczywistych profili glebowych. Uwzględnione profile glebowe były reprezentatywne dla powyższych lokalizacji. Kalibrację przeprowadziłem, w pierwszym kroku, dla parametrów wpływających na fenologię tak, by skalibrowany model odtwarzał ją możliwie najdokładniej, a następnie kalibrowałem parametry wpływające na uzyskiwany plon oraz całkowitą biomasę. Skalibrowany model był następnie wykorzystany, by oszacować poziom produkcji rolnej w warunkach zmieniającego się klimatu. W tym celu stosowano wartości dobowych szeregów meteorologicznych temperatury powietrza i opadu uwzględniające prognozowane w scenariuszach zakresy zmian w stosunku do wartości bazowych. Zarejestrowane wartości parametrów meteorologicznych z okresu od 1981 do 2010 roku posłużyły, by zamodelować plon, który posłużył jako poziom odniesienia. W modelowaniu uwzględniono trzy poziomy koncentracji CO₂ w atmosferze: 360, 447 i 522 ppm, reprezentujące prognozowane stężenia aż do 2070. Analizę wpływu zmian klimatycznych na poziom plonowania pszenicy przeprowadzono stosując metodę powierzchni odpowiedzi IRS. W kolejnym kroku w badaniach uwzględniono następujące zabiegi adaptacyjne: skrócenie lub wydłużenie o 10% czasu trwania faz fenologicznych odmiany standardowej; przyspieszenie daty siewu o 15 dni oraz jej opóźnienie o 30 dni w stosunku do standardowej daty siewu; usunięcie wernalizacji (stosowanie odmiany jarej); a także dodatkowe nawadnianie w momencie kwitnienia oraz, w celu oceny potencjalnego poziomu produkcji, nawadnianie do poziomu całkowitego zaspokojenia zapotrzebowania na wodę w każdej fazie wzrostu pszenicy. Analiza wpływu zabiegów adaptacyjnych na zmiany w poziomie produkcji roślinnej w warunkach zmieniającego się klimatu została przeprowadzona z wykorzystaniem metody adaptacyjnych powierzchni odpowiedzi ARS.

Przeprowadzone przeze mnie badania modelowe były częścią większej całości - analizowane były również wyniki otrzymane przez współautorów publikacji przy użyciu 13 innych modeli. Dzięki temu możliwe było wykonanie zarówno analiz porównawczych wyników pochodzących z różnych modeli, jak i uzyskania wartości uśrednianej po zespole modeli. Przeprowadzenie uśredniania po zespole modeli pozwoliło na stworzenie bardziej wiarygodnych rekomendacji, które kombinacje zabiegów adaptacyjnych stosować, by w badanej lokalizacji, w warunkach zmieniającego się klimatu, uzyskać wyższy plon.

Wyniki, podsumowanie i wnioski

Z przeprowadzonych analiz wynika, że, przy zadanej koncentracji CO₂ w atmosferze, rosnące wartości średnich temperatur oraz zmniejszająca się intensywność opadu ma negatywny wpływ na uzyskiwany plon. Zwiększona intensywność opadu ma z kolei korzystny wpływ na uzyskiwany plon i ma potencjał, by w pewnym stopniu równoważyć negatywny wpływ rosnących wartości średnich temperatur. Zaobserwowano pozytywny wpływ wyższych koncentracji CO₂ w atmosferze na intensyfikację produkcji roślinnej.

Analiza wpływu zabiegów adaptacyjnych na zmiany w poziomie produkcji roślinnej w warunkach zmieniającego się klimatu wskazuje, iż dla lokalizacji charakteryzujących się klimatem śródziemnomorskim możliwe jest przeprowadzenie takich zabiegów adaptacyjnych, które skutkują uzyskaniem wyższego plonu. Największą intensyfikację produkcji roślinnej uzyskano stosując dodatkowe nawadnianie. Zarówno dodatkowe nawadnianie w momencie kwitnienia, jak i nawadnianie do poziomu całkowitego zaspokojenia zapotrzebowania na wodę w każdej fazie wzrostu pszenicy, zwiększa w znaczącym stopniu uzyskiwany plon. Ma to najprawdopodobniej związek z warunkami klimatycznymi lokalizacji wybranej do przeprowadzenia analiz, w której wzrost i rozwój roślin jest ograniczony z powodu niedostatecznej ilości opadów atmosferycznych. Inne opcje pojedynczej adaptacji nie były w stanie zrównoważyć szkodliwego wpływu złożonych interakcji wynikających z jednoczesnych zmian temperatur, opadu czy koncentracji CO₂ w atmosferze. Spośród analizowanych zabiegów adaptacyjnych, maksymalizacją uzyskiwanego plonu charakteryzowały się kombinacje związane ze stosowaniem dodatkowego nawadniania w momencie kwitnienia i stosowaniem odmiany jarej, odmiany o krótszym czasie trwania faz fenologicznych i wysiewanej we wcześniejszym terminie. Kombinacje te pozwalały na zintensyfikowanie produkcji rolniczej nawet dla umiarkowanych wartości modyfikacji w prognozowanych przebiegach szeregów temperatury i opadu, a w niektórych przypadkach - na utrzymanie wydajności produkcji dla ekstremalnych wartości zmian w tych szeregach. Zauważono, że w przypadku wielu kombinacji związanych ze zmianą czasu trwania faz fenologicznych oraz terminu siewu, to dodatkowe nawadnianie w momencie kwitnienia jest czynnikiem wpływającym na to, czy skutkują one intensyfikacją uzyskiwanego plonu.

Podsumowanie i wnioski

Przeprowadzone badania wykazały, iż szeregi czasowe wielkości agrometeorologicznych wykazują multifraktalność, której głównym źródłem jest obecność korelacji długozasięgowych w strukturze tych szeregów. Metoda MF-DFA umożliwiła nie tylko na jakościowe scharakteryzowanie złożoności struktury szeregów czasowych, ale także, dzięki ocenie wartości parametrów α_0 , α_s oraz w charakteryzujących te widma, na ilościowy opis różnic w dynamice procesów pomiędzy analizowanymi wielkościami meteorologicznymi, lokalizacjami oraz okresami. Zróżnicowanie przestrzenne parametrów opisujących widmo wskazuje, iż metodę MF-DFA można stosować do oceny różnic w dynamice procesów agrometeorologicznych dla lokalizacji o zróżnicowanych warunkach klimatycznych. Multifraktalność opadu znacznie różni się od multifraktalności pozostałych wielkości agrometeorologicznych, nie tylko wykazując największe zróżnicowanie parametrów charakteryzujących widma osobliwości tej wielkości pomiędzy analizowanymi lokalizacjami i okresami, ale także ze względu na to, iż jej przyczyną jest zarówno obecność ogonów w rozkładzie funkcji gęstości prawdopodobieństwa, jak i z obecność korelacji długozasięgowych w ich strukturze. Sugeruje to, że spośród badanych elementów meteorologicznych, opad może być wielkością najbardziej podatną na zmiany w dynamice klimatu.

Obecność korelacji długozasięgowych w strukturze szeregów czasowych wielkości agrometeorologicznych oraz zauważony wpływ agregacji przestrzenno-czasowej na ich wła-

sności skalowania, powinny być uwzględniane w badaniach zmian klimatycznych oraz w modelowaniu produkcji rolniczej. Nieuwzględnienie tych czynników może być źródłem powstania nieoczekiwane dużych błędów oszacowań. Do prognoz przyszłych przebiegów szeregów czasowych powinno się stosować metody, które odtwarzają inherentne właściwości struktury szeregów, w szczególności korelacje długozasięgowe.

Informacje uzyskane z analizy dynamiki szeregów meteorologicznych dla różnych lokalizacji w Europie mogą być wykorzystane do planowania eksperymentów modelowania wpływu zabiegów adaptacyjnych na zmiany w poziomie produkcji roślinnej w warunkach zmieniającego się klimatu. Dotyczy to zarówno określania skali przestrzennej, jak i czasowej takich analiz, ale też opracowania procedury przygotowania przebiegów wartości dobowych szeregów czasowych różnych wielkości agrometeorologicznych oddających przyszłe warunki klimatyczne i zachowujących właściwości skalowania.

Literatura

- Anderson W., You L., Wood S., Wood-Sichra U., Wu, W. (2014): *A comparative analysis of global cropping systems models and maps*. IFPRI Discussion Paper 1327. Washington, D.C.: International Food Policy Research Institute (IFPRI).
- Asseng, S., Ewert F., Rosenzweig C., Jones J.W., Hatfield J.L., Ruane A.C., Boote K.J., Thorburn P.J., Rötter R.P., Cammarano D., Brisson N., Basso B., Martre P., Aggarwal P.K., Angulo C., Bertuzzi P., Biernath C., Challinor A.J., Doltra J., Gayler S., Goldberg R., Grant R., Heng L., Hooker J., Hunt L.A., Ingwersen J., Izaurralde R.C., Kersebaum K.C., Müller C., Naresh Kumar S., Nendel C., O'Leary G., Olesen J.E., Osborne T.M., Palosuo T., Priesack E., Ripoche D., Semenov M.A., Shcherbak I., Steduto P., Stöckle C., Stratonovitch P., Streck T., Supit I., Tao F., Travasso M., Waha K., Wallach D., White J.W., Williams J.R., Wolf J. (2013): *Uncertainty in simulating wheat yields under climate change*. Nature Climate Change, 3, 827-832. <https://doi.org/10.1038/nclimate1916>
- Asseng S., Ewert F., Martre P., Rötter R.P., Lobell D.B., Cammarano D., Kimball B.A., Ottman M.J., Wall G.W., White J.W., Reynolds M.P., Alderman P.D., Prasad P.V.V., Aggarwal P.K., Anothai J., Basso B., Biernath C., Challinor A.J., De Sanctis G., Doltra J., Fereres E., Garcia-Vile M., Gayler S., Hoogenboom G., Hunt L.A., Izaurralde R.C., Jabloun M., Jones C.D., Kersebaum K.C., Koehler A.K., Muller C., Kumar S.N., Nendel C., O'Leary G., Olesen J.E., Palosuo T., Priesack E., Rezaei E.E., Ruane A.C., Semenov M.A., Shcherbak I., Stockle C., Stratonovitch P., Streck T., Supit I., Tao F., Thorburn P.J., Waha K., Wang E., Wallach D., Wolf I., Zhao Z., Zhu Y. (2015): *Rising temperatures reduce global wheat production*. Nature Climate Change, 5, 143-147.
- Balling R.C., Vose R.S., Weber G.R. (1998): *Analysis of long-term European temperature records: 1751-1995*. Climate Research, 10, 193-200.
- Bartos I., Jánosi I.M. (2006): *Nonlinear correlations of daily temperature records over land*. Nonlinear Processes in Geophysics, 13, 571-576.
- Benzi R. (2010): *Stochastic resonance: from climate to biology*. Nonlinear Processes in Geophysics, 17, 431-441. <https://doi.org/10.5194/npg-17-431-2010>
- Bonhomme R. (2000): *Bases and limits to using 'degree.day' units*. European Journal of Agronomy, 13, 1-10.
- Box G.E.P., Jenkins G. (1970): *Time series analysis: forecasting and control*. San Francisco, Holden-Day.
- Box G.E.P., Tiao G.C. (1975): *Intervention Analysis with Applications to Economic and Environmental Problems*. Journal of the American Statistical Association, 70, 70-79.
- Cleveland R.B., Cleveland W.S., McRae J.E., Terpenning I. (1990): *STL: a seasonal-trend decomposition procedure based on loess*. Journal of Official Statistics, 6, 3-33.
- Cristescu C.P., Stan C., Scarlat E.I. (2007): *Multifractal analysis of the dynamics of the Romanian exchange rate ROLUSD during the transition period*. University Politehnica of Bucharest Scientific Bulletin, Series A: Applied Mathematics and Physics, 69, 37-44.
- de Lima M.I.P., de Lima J.L.M.P. (2009): *Investigating the multifractality of point precipitation in the Madeira archipelago*. Nonlinear Processes in Geophysics, 16, 299-311.

- FAO (2016): *Climate change and food security: risks and responses*. Rome, Italy: FAO.
- FAO (2009): *How to feed the world in 2050*. Proceedings of a Technical Meeting of Experts, Rome, Italy: FAO.
- Feng T., Fu Z., Deng X., Mao J. (2009): *A brief description to different multifractal behaviors of daily wind speed records over China*. Physics Letters A, 373, 4134-4141.
- Fronzek S., Carter T.R., Raisanen J., Ruokolainen L., Luoto M. (2010): *Applying probabilistic projections of climate change with impact models: a case study for sub-arctic tundra fires in Fennoscandia*. Climate Change, 99, 515-534.
- García-Marín A.P., Jiménez-Hornero F.J., Ayuso J.L. (2008): *Applying multifractality and the self-organized criticality theory to describe the temporal rainfall regimes in Andalusia (southern Spain)*. Hydrological Processes, 22, 295-308.
- Gemmer M., Fischer T., Su B., Liu L.L. (2011): *Trends of precipitation extremes in the Zhujiang River Basin, South China*. Journal of Climate, 24, 750-761.
- Higuchi T. (1988): *Approach to an irregular time series on the basis of the fractal theory*. Physica D, 31, 277-283.
- Hodges, T. (1990): *Predicting crop phenology*. CRC Press, Boca Raton, FL.
- Hoogenboom G., White J.W., Messina C.D. (2004): *From genome to crop: integration through simulation modeling*. Field Crops Research, 90, 145-163. <https://doi.org/10.1016/j.fcr.2004.07.014>
- Huntingford C., Jones P.D., Livina V.N., Lenton T.M., Cox P.M. (2013): *No increase in global temperature variability despite changing regional patterns*. Nature, 500, 327-330.
- Ihlen E.A. (2012): *Introduction to multifractal detrended fluctuation analysis in matlab*. Frontiers in Physiology, 3, 141. <http://dx.doi.org/10.3389/fphys.2012.00141>
- Jiang L., Zhao J., Li N., Li F., Guo Z. (2013): *Different multifractal scaling of the 0 cm average ground surface temperature of four representative weather stations over China*. Advances in Meteorology, 2013, 341934. <https://doi.org/10.1155/2013/341934>
- Kalauzi A., Spasić S., Čulić M., Grbić G., Martać Lj. (2005): *Consecutive differences as a method of signal fractal analysis*. Fractals, 13, 283-292.
- Kantelhardt J.W., Zschiegner S.A., Koscielny-Bunde E., Havlin S., Bunde A., Stanley H.E. (2002): *Multifractal detrended fluctuation analysis of nonstationary time series*. Physica A, 316, 87-114.
- Kantelhardt J.W., Koscielny-Bunde E., Rybski D., Braun P., Bunde A., Havlin S. (2006): *Long-term persistence and multifractality of precipitation and river runoff records*. Journal of Geophysical Research, 111, D01106.
- Kavasseri R.G., Nagarajan R. (2005): *A multifractal description of wind speed records*. Chaos, Solitons & Fractals, 24, 165-173.
- Király A., Jánosi I.M. (2005): *Detrended fluctuation analysis of daily temperature records: geographic dependence over Australia*. Meteorology and Atmospheric Physics, 88, 119-128.
- Koscielny-Bunde E., Roman H.E., Bunde A., Havlin S., Schellnhuber H.J. (1998): *Long-range power-law correlations in local daily temperature fluctuations*. Philosophical Magazine B, 77, 1331-1340.
- Li E., Mu X., Zhao G., Gao P. (2015): *Multifractal detrended fluctuation analysis of streamflow in the Yellow River Basin, China*. Water, 7, 1670-1686. <https://doi.org/10.3390/w7041670>
- Livina V.N., Ashkenazy Y., Bunde A., Havlin S. (2011): *Seasonality effects on nonlinear properties of hydro-meteorological records*. In Extremis: Disruptive Events and Trends in Climate and Hydrology, 267-284.
- Lovejoy S., Pielou J., Schertzer D. (2012): *The global space-time cascade structure of precipitation: satellites, gridded gauges and reanalyses*. Advances in Water Resources, 45, 37-50.
- López J.L., Contreras J.G. (2013): *Performance of multifractal detrended fluctuation analysis on short time series*. Physical Review E, 87, 022918.
- Luo Q., Bellotti W., Williams M., Cooper I., Bryan B. (2007): *Risk analysis of possible impacts of climate change on South Australian wheat production*. Climate Change, 85, 89-101.
- Martre P., Wallach D., Asseng S., Ewert F., Jones J.W., Rötter R.P., Boote K.J., Ruane A.C., Thorburn P.J., Cammarano D., Hatfield J.L., Rosenzweig C., Aggarwal P.K., Angulo C., Basso B., Bertuzzi P., Biernath C., Brisson N., Challinor A.J., Doltra J., Gayler S., Goldberg R., Grant R.F., Heng L., Hooker J., Hunt L.A., Ingwersen J., Izaurralde R.C., Kersebaum K.C., Muller C., Kumar S.N., Nendel C., O'Leary G., Olesen

- J.E., Osborne T.M., Palosuo T., Priesack E., Ripoche D., Semenov M.A., Shcherbak I., Steduto P., Stockle C.O., Stratonovitch P., Streck T., Supit I., Tao F.L., Travasso M., Waha K., White J.W., Wolf J. (2015): *Multimodel ensembles of wheat growth: many models are better than one* Global Change Biology, 21, 911-925.
- Pathirana A., Herath S. (2002): Multifractal modelling and simulation of rain fields exhibiting spatial heterogeneity. *Hydrology and Earth System Sciences*, 6, 695-708.
- Mądry W. (1995): *Ogólna charakterystyka wybranych modeli symulujących wzrost, rozwój i plonowanie roślin*. *Fragmenta Agronomica*, 12, 5-17.
- Nguyen T-L., Chen P-J., Shu M-H., Hsu B-M., Lai Y-C. (2013): *Forecasting with Fourier Residual Modified Arima Model: The Case of Air Cargo in Taiwan*. Diversity, Technology, and Innovation for Operational Competitiveness: Proceedings of the 2013 International Conference on Technology Innovation and Industrial Management, ToKnowPress, S5135-S5146.
- Oświęcimka P., Kwapien J., Drożdż S. (2006): *Wavelet versus detrended fluctuation analysis of multifractal structures*. *Physical Review E*, 74, 016103.
- Palosuo T., Kersebaum K.C., Angulo C., Hlavinka P., Moriondo M., Olesen J.E., Patil R.H., Ruget F., Rumbaer C., Takac J., Trnka M., Bindi M., Caldag B., Ewert F., Ferrise R., Mirschel W., Saylan L., Siska B., Rötter R.P. (2011): *Simulation of winter wheat yield and its variability in different climates of Europe: a comparison of eight crop growth models*. *European Journal Of Agronomy*, 35, 103-114.
- Peng C-K., Buldyrev S.V., Havlin S., Simons M., Stanley H.E., Goldberger A.L. (1994): *Mosaic organization of DNA nucleotides*. *Physical Review E*, 49, 1685-1689. <https://doi.org/10.1103/PhysRevE.49.1685>
- Rodríguez R., Casas M.C., Redaño A. (2013): *Multifractal analysis of the rainfall time distribution on the metropolitan area of Barcelona (Spain)*. *Meteorology and Atmospheric Physics*, 121, 181-187.
- Ruane A.C., McDermid S., Rosenzweig C., Baigorría G.A., Jones J.W., Romero C.C., Dwayne Cecil L. (2014): *Carbon-temperature-water change analysis for peanut production under climate change: a prototype for the AgMIP Coordinated Climate-Crop Modeling Project (C3MP)*. *Global Change Biology*, 20, 394-407.
- Sánchez R., Carreras B.A., van Milligen B.P. (2005): *Fluid limit of nonintegrable continuous-time random walks in terms of fractional differential equations*. *Physical Review E*, 71, 011111. <https://doi.org/10.1103/PhysRevE.71.011111>
- Scarlat E.I., Stan C., Cristescu C.P. (2007): *Self-similar characteristics of the currency exchange rate in an economy in transition*. *Physica A: Statistical Mechanics and its Applications*, 379, 188-198.
- Swanson K.L., Tsonis A.A. (2010): *Has the climate recently shifted?* *Theoretical and Applied Climatology*, 102, 75-85.
- Theiler J., Eubank S., Longtin A., Galdrikian B., Doynne Farmer J. (1992): *Testing for nonlinearity in time series: the method of surrogate data*. *Physica D: Nonlinear Phenomena*, 58, 77-94. [https://doi.org/10.1016/0167-2789\(92\)90102-S](https://doi.org/10.1016/0167-2789(92)90102-S)
- UN DEPA (2017): *World Population Prospects 2017*. United Nations (UN), Department of Economic and Social Affairs, New York, USA. <https://esa.un.org/unpd/wpp>
- Valencia J.L., Requejo A.S., Gasco J.M., Tarquis A.M (2010): *A universal multifractal description applied to precipitation patterns of the Ebro River Basin, Spain*. *Climate Research*, 44, 17-25.
- Wang X., Mei Y., Li W., Kong Y., Cong X. (2016): *Influence of sub-daily variation on multi-fractal detrended fluctuation analysis of wind speed time series*. *PLoSOne*, 11(1), e0146284. <http://dx.doi.org/10.1371/journal.pone.0146284>
- White J.W., Hoogenboom G., Kimball B.A., Wall G.W. (2011): *Methodologies for simulating impacts of climate change on crop production*. *Field Crops Research*, 124, 357-368.
- Wilkerson F.D., Lambart J.R., Landivar J.A. (1981): In *"predicting tillage effects on soil physical properties and processes"*. Chapter 11, 179-198.
- Yonghe L., Kexin Z., Wanchang Z., Yuehong S., Hongqin P., Jinming F. (2013): *Multifractal analysis of 1-min summer rainfall time series from a monsoonal watershed in eastern China*. *Theoretical and Applied Climatology*, 111, 37-50.
- Zhao G., Siebert S., Enders A., Rezaei E.E., Yan C., Ewert F. (2015): *Demand for multi-scale weather data for regional crop modelling*. *Agricultural and Forest Meteorology*, 200, 156-171.

5. Omówienie pozostałych osiągnięć naukowo-badawczych:

Moja działalność naukowo-badawcza rozpoczęła się w 2006 r., po ukończeniu stacjonarnych studiów magisterskich na Wydziale Matematyki, Fizyki i Informatyki Uniwersytetu Marii Curie Skłodowskiej w Lublinie, na kierunku fizyka (specjalność fizyka teoretyczna). Po obronie pracy pt. *Dynamika par Coopera w układach fermionów z oddziaływaniem zależnym od czasu*, napisanej w Zakładzie Teorii Fazy Skondensowanej pod kierunkiem prof. dr hab. Karola I. Wysokińskiego oraz promotora pomocniczego dr hab. Tadeusza Domańskiego, i uzyskaniu tytułu **magistra** nauk fizycznych w zakresie fizyki, zdałem egzaminy wstępne i zostałem przyjęty na Studia Doktoranckie na Wydziale Fizyki, Matematyki i Informatyki Uniwersytetu Marii Curie-Skłodowskiej w Lublinie. Od października 2006 r. kontynuowałem edukację jako uczestnik studiów doktoranckich w Zakładzie Teorii Fazy Skondensowanej. Pracując pod opieką prof. dr hab. Karola I. Wysokińskiego napisałem pracę doktorską pt. *Teoretyczny opis niejednorodności w nadprzewodnikach*, którą obroniłem z **wyróżnieniem** dnia 9.05.2011 r. Stopień doktora nauk fizycznych w zakresie fizyki nadany mi został w dniu 30.05.2011 r. przez Radę Wydziału Matematyki, Fizyki i Informatyki Uniwersytetu Marii Curie Skłodowskiej. Okres Studiów Doktoranckich i przygotowywania dysertacji doktorskiej owocował **7** opublikowanymi pracami naukowymi mojego współautorstwa, w tym **4** w czasopiśmie punktowanym według listy Ministerstwa Nauki i Szkolnictwa Wyższego i posiadających Impact Factor. W tym czasie brałem aktywny udział w **6** konferencjach oraz w **3** warsztatach, prezentując wyniki swoich badań tak w języku angielskim, jak i polskim, zarówno w formie prezentacji plakatowej, jak i referatu. Na XIV Krajowej Szkole Nadprzewodnictwa pt. *Nadprzewodnictwo i niejednorodne układy skondensowane*, odbywającej się w Ostrowie Wielkopolskim (Polska) w dniach 13–17.10.2009 r., poster mojego autorstwa (**III.B.72**) został **wyróżniony** i zdobył **nagrodę** dla najlepszego plakatu. Ponadto, w listopadzie 2010 r., zostałem zaproszony przez prof. Carstena Timma, by wygłosić na Uniwersytecie Technicznym w Dreźnie wykład pod tytułem *Is there a possibility to explain inhomogeneities observed in superconductors by the means of the Boson-Fermion model?* (**III.Q.1**). W lipcu 2011 r. na zaproszenie Lubelskiego Stowarzyszenia Fantastyki „Cytadela Syriusza” wygłosiłem popularnonaukową prelekcję pod tytułem *Między science a fiction* (**III.I.2**). W latach 2007-2011 realizowałem dwa granty naukowe jako wykonawca - N N202 1878 33 *Transport kwantowy i nadprzewodnictwo w materiałach litych i nanoskopowych*, kierowany przez prof. dr hab. Karola I. Wysokińskiego (**II.I.10**), oraz N N202 263138 *Rola korelacji, nieporządku i efektów włączeniowych w układach elektronowych*, kierowany przez dr hab. Tadeusza Domańskiego (**II.I.11**).

Opis silnie skorelowanych i niejednorodnych warstw nadprzewodzących przy wykorzystaniu modelu bozonowo-fermionowego

Studia doktoranckie pozwoliły mi na zapoznanie się ze specyfiką pracy naukowej oraz na uzyskanie i rozwinięcie umiejętności analizy teoretycznej zagadnień, a następnie opracowaniu komputerowego modelu danego problemu i jego rozwiązaniu. Jestem autorem kodów programów rozwiązujących zagadnienie czasowej zależności współczynników koherencyjnych występujących w równaniach BCS (Bardeen-Cooper-Schrieffer) metodą Rungego-Kutty. Korzystając z modeli BCS oraz BF (bozonowo-fermionowego), przetransformowanych do prze-

strzeni rzeczywistej, zamodelowałem powierzchnię niejednorodnego nadprzewodnika wysokotemperaturowego i uzyskałem wyniki zbliżone do zależności obserwowanych eksperymentalnie. Matematycznie zadanie to polegało na rozwiązaniu w sposób samouzdogniony zagadnienia własnego dla ogromnych macierzy. W tym celu wykorzystywałem własnoręcznie napisany kod oraz biblioteki Lapack i ScaLapack. Wynikiem przeprowadzonych badań był cykl sześciu publikacji (**II.A.10**, **II.A.11**, **II.A.12**, **II.A.13**, **II.A.14** oraz **II.D.9**) i trzech doniesień konferencyjnych (**II.E.51**, **II.E.52** oraz **II.E.53**), a otrzymane rezultaty prezentowane były na pięciu konferencjach (**III.B.67**, **III.B.68**, **III.B.69**, **III.B.71**, **III.B.72**, **III.B.73**) oraz na jednych warsztatach (**III.B.70**). Innym istotnym oraz nowatorskim wynikiem otrzymanym w trakcie pisanie pracy doktorskiej było wprowadzenie do modelu BF nadprzewodnictwa członu opisującego silne korelacje i rozwiązanie tego zagadnienia z wykorzystaniem przybliżenia Gutzwillera. Pozwoliło to na zamodelowanie powierzchni silnie skorelowanego i nieuporządkowanego nadprzewodnika wysokotemperaturowego. Wynikiem realizacji powyższego zagadnienia była jedna publikacja (**II.A.15**) i jedno doniesienie konferencyjne (**II.E.54**), a uzyskane rezultaty zostały zaprezentowane na jednej konferencji (**III.B.75**) i jednych warsztatach (**III.B.74**). Zostałem również zakwalifikowany, jako jedyna osoba z Polski, do uczestnictwa w warsztatach prezentujących zastosowanie metody DFT (Dynamic Field Theory) i miałem okazję wyjechać do Santander w Hiszpanii, by zapoznać się i nauczyć obsługi kodu DFT SIESTA (**III.B.77**) oraz do Jülich w Niemczech, gdzie z kolei zapoznałem się z metodą funkcjonału gęstości i kodem DFT FLEUR (**III.B.78**). Badana tematyka oraz uczestnictwo w warsztatach pozwoliły mi na dogłębne poznanie metod służących wykonywaniu symulacji numerycznych w badaniach naukowych.

Procesy transportu masy i energii w układzie gleba-roślina-atmosfera

W marcu 2012 r. zostałem zatrudniony w Zakładzie Metrologii i Modelowania Procesów Agrofizycznych Instytutu Agrofizyki im. Bohdana Dobrzańskiego Polskiej Akademii Nauk jako wykonawca w projektach badawczych NCN 2011/01/B/ST10/07544 *Opracowanie modeli PTF krzywej retencji wodnej z uwzględnieniem efektu histerezy* (**II.I.1**) oraz FACCEJPI/06/2012 pt. *Modelowanie Europejskiego Rolnictwa ze Zmianami Klimatu dla Bezpieczeństwa Żywności / Modelling European Agriculture with Climate Change for Food Security* Knowledge Hub FACCE MACSUR (**II.I.3**), kierowanych przez prof. dr hab. Cezarego Sławińskiego. Praca pod kierownictwem prof. dr hab. Cezarego Sławińskiego pozwoliła mi na zapoznanie się z profilem badań prowadzonych w Zakładzie Metrologii i Modelowania Procesów Agrofizycznych, jak również na znaczne rozwinięcie umiejętności pracy w laboratorium eksperymentalnym, w szczególności w zakresie pobierania i preparatyki próbek glebowych oraz planowania i wykonywania eksperymentów doświadczalnych. Brałem udział w uruchomieniu i realizacji doświadczalnej części badań dotyczących zjawiska histerezy krzywej retencji ośrodków porowatych, a także w realizacji doświadczenia sprawdzającego istnienie zależności mierzonej wilgotności od sposobu umieszczenia sond TDR. W 2013 roku zostałem zatrudniony na etacie adiunkta w Zakładzie Metrologii i Modelowania Procesów Agrofizycznych Instytutu Agrofizyki im. Bohdana Dobrzańskiego Polskiej Akademii Nauk. Wtedy też zająłem się badaniami nad wybranymi, niezbyt dobrze poznanymi do tej pory, procesami transportu masy

i energii w układzie gleba-roślina-atmosfera. Są to procesy niezwykle istotne, jako że modyfikują aktywność biologiczną oraz dostępność wody dla roślin, regulują czynne parowanie wody z nadziemnych części roślin (transpirację), odpowiadają za uzupełnianie wód gruntowych, kontrolują przepływy oraz pełnią wiele innych ważnych funkcji w środowisku. Z tych powodów modelowanie procesów transportu w ośrodkach porowatych ma wiele zastosowań w dziedzinach takich jak hydrologia, meteorologia, agrofizyka, ochrona środowiska, a nawet energetyka oraz przemysł spożywczy czy chemiczny. Rezultaty badań prowadzonych w okresie 2012-2013 zostały opublikowane w dwóch pracach naukowych w czasopiśmie punktowanym według listy Ministerstwa Nauki i Szkolnictwa Wyższego i posiadających Impact Factor. Pierwsza z nich, opublikowana jeszcze 2013 r., w *Vadose Zone Journal* (**II.A.1**), dotyczyła modelowania zmian wilgotności w profilu glebowym w warunkach naturalnych. W pracy porównałem wyniki uzyskane z wykorzystaniem klasycznej metody modelowania bazującej na równaniach fizycznych (Richardsa) z wynikami uzyskanymi z wykorzystaniem metody wywodzącej się z uczenia maszynowego (soft-learning i data mining), jakim jest metoda wektorów wspierających SVM (Supporting Vector Machine). Jako model fizyczny wykorzystujący równanie Richardsa, zastosowany został zaimplementowany w komercyjnym oprogramowaniu HYDRUS-1D model podwójnej porowatości (ang. dual-porosity). Do uczenia (SVM) i kalibracji (HYDRUS-1D) modeli, a także do walidacji ich zdolności predykcyjnych wykorzystano dane z dwuletniego eksperymentu polowego przeprowadzonego na stacji agrometeorologicznej przy IA PAN w Lublinie. W pracy pokazałem, iż obydwie metody umożliwiają prognozowanie wilgotności gleby na podstawie warunków meteorologicznych, a technika SVM stanowi atrakcyjną alternatywę dla fizycznych modeli bazujących na równaniu Richardsa, ponieważ charakteryzuje się dokładnością porównywalną, albo nawet lepszą, niż model fizyczny, a nie wymaga znajomości właściwości fizycznych gleby. Druga praca, opublikowana w 2014 r. w *Measurement* (**II.A.2**) była wynikiem badań nad zależnością wilgotności mierzonej przez sondy TDR od sposobu umieszczenia tych sond w próbce. Motywacją do podjęcia takiej tematyki badań było opracowanie koncepcji urządzenia pomiarowego pozwalającego na zautomatyzowany pomiar krzywej retencji gleb w procesach nawilżania i osuszania w projekcie (**II.I.1**). Opracowana aparatura wykorzystuje do pomiaru wilgotności gleby standardową w pomiarach tego typu technikę TDR, lecz jego budowa wymusza korzystanie raczej z 1 sondy, w przeciwieństwie do ogólnie zaakceptowanej procedury wykorzystującej 3 sondy pomiarowe. W pracy analizowane były próbki glebowe o standardowej objętości (100 cm^3), pobrane zarówno w stanie nienaruszonym, jak i przygotowane w sposób sztuczny (usypane), z materiału o znanym rozkładzie granulometrycznym. Sondy były umieszczane horyzontalnie i wertykalnie w próbkach. Z przeprowadzonych badań wyciągnąłem wniosek, iż wynik pomiaru sondą TDR stanowi średnią arytmetyczną z pewnej objętości gleby zlokalizowanej w bliskiej okolicy igieł czujnika, zarówno w pomiarze statycznym, jak i dynamicznych procesach nawilżania i osuszania próbki, a pomiar wykonany przy pomocy jedynie jednej sondy umieszczonej wertykalnie jest wystarczająco reprezentatywny i dokładny, by móc być uznanym za równoważny procedurze standardowej wykorzystującej 3 sondy umieszczone horyzontalnie. Rezultaty badań nad powyższymi dwoma zagadnieniami zaprezentowane były na V Zjeździe Naukowym Polskiego Towarzystwa Agrofizycznego w Puławach (**III.B.1**) i konferencjach 20th International Poster Day w Bratysławie (**III.B.37**) oraz 10th International Conference on Agrophysics ICA13 w Lublinie (**II.B.2**, **III.B.38**), w wyniku czego powstały 4 doniesienia konferencyjne (**II.E.1**, **II.E.2**,

II.E.3, II.E.4). W tym czasie, dzięki przeprowadzeniu gruntownego przeglądu literatury do publikacji w *Vadose Zone Journal* i *Measurement* i gruntownym pogłębieniu wiedzy, brałem także udział w stworzeniu koncepcji i pisaniu 3 rozdziałów dotyczących modelowania ośrodka glebowego i procesów w niej zachodzących do monografii „AGROFIZYKA procesy, właściwości, metody” wydanej w 2014 r. (**II.D.1, II.D.2** oraz **II.D.3**).

Monitoring środowiska wzrostu roślin i jakości płodów rolnych

W 2013 roku, realizując projekt FACCE MACSUR (**II.I.3**), rozszerzyłem zakres swoich zainteresowań naukowe o tematykę badawczą związaną z szeroko pojętym monitoringiem i modelowaniem środowiska wzrostu roślin i jakości płodów rolnych w kontekście adaptacji rolnictwa do zmian klimatu. Zmiany klimatyczne stanowią zarówno zagrożenie, jak i szansę dla produkcji roślinnej, wpływając nie tylko na wielkość zbiorów, ale sprawiając także, iż lokalizację i strukturę zasiewu należy odpowiednio dopasować. Przyczyny obserwowanych obecnie zmian klimatycznych są tematem intensywnych badań i wciąż nie istnieje konsensus, czy są one wynikiem naturalnych czy antropogenicznych czynników. Niemniej jednak większość środowiska naukowego skłania się ku opinii, iż za zmiany obserwowane w ostatnich latach, szczególnie stale rosnący poziom stężenia CO₂ w atmosferze, winą należy obarczyć działalność człowieka i związane z tą działalnością emisje nadmiarowych ilości gazów cieplarnianych do atmosfery. Niewątpliwie udział rolnictwa w tym wzroście jest istotny, głównie za sprawą przekształcania nowych terenów na użytki rolnicze oraz stosowania nawozów sztucznych i organicznych. Jednym z zadań w projekcie badawczo-rozwojowym *FACCE MACSUR* (**II.I.3**) było opracowanie i założenie eksperymentalnego protokołu polowego na Lubelszczyźnie w celu monitorowania zmian zachodzących w agroekosystemach zlokalizowanych w tej części Europy. W celu realizacji tego zadania brałem udział w szkole letniej w Mierzęcinie (**III.B.63**), która pozwoliła mi zapoznać się z metodyką pomiaru gazów szklarniowych z pól uprawnych oraz metodami analizy danych pochodzących z pomiarów gazów cieplarnianych. Po dokonaniu wyboru Stanów Nowych jako miejsca lokalizacji eksperymentu, zajmowałem się przygotowaniem koncepcji i instalacją niezbędnych komponentów zestawu pomiarowego do mierzenia emisji CO₂ z pól uprawnych, a następnie brałem udział w kampaniach polowych, w trakcie których, korzystając z metody komór dynamicznych przeprowadzałem pomiary emisji (pochłaniania) gazów szklarniowych zarówno z gleby, jak i łanu. Dodatkowo zajmowałem się przeprowadzaniem pomiarów stanu fitosanitarnego upraw oraz właściwości fizykochemicznych gleby, analizą i opracowaniem danych za zdjęć multispektralnych gleby i pokrywy roślinnej oraz analizą danych meteorologicznych. Uzyskane wyniki przedstawione zostały na dwóch konferencjach naukowych, w wyniku czego powstały dwa doniesienia konferencyjne (**II.E.7** oraz **II.E.9**) i stały się pośrednim powodem odbycia stażu naukowego w Institute of Bio- and Geosciences Agrosphere (IBG-3) w Forschungszentrum Jülich w Niemczech (**III.L.1**), w trakcie którego nauczyłem się obsługi opracowanego w tej instytucji modelu AGRO-C i który skalibrowałem dla pola w Stanach Nowych korzystając ze zmierzonych i opracowanych danych. Zagadnienie pomiaru emisji gazów szklarniowych kontynuowałem wykonując dwa projekty badawcze uzyskane w ramach strategicznego programu badań naukowych i prac rozwojowych BIOSTRATEG (**II.I.5** oraz **II.I.7**). W pierwszym z nich, LCAgri

(II.I.5) pomiary emisji zostały rozszerzone o podtlenek azotu i metan dzięki zakupowi dodatkowych analizatorów, a ja zajmowałem się opracowaniem założeń przeprowadzania eksperymentów polowych, polowymi pomiarami stanu fitosanitarnego roślin oraz emisji CO₂, N₂O i CH₄ dla uprawy wybranych zbóż, a także modelowaniem emisji powyższych gazów przy różnych zabiegach uprawowych i adaptacyjnych w poszukiwaniu takiej kombinacji, która skutkuje najniższą emisją gazów szklarniowych. W projekcie GyroScan **(II.I.7)** mam za zadanie przeprowadzić pomiary stanu fitosanitarnego oraz polowych emisji CO₂, N₂O i CH₄ z upraw pszenicy ozimej i kukurydzy w warunkach zróżnicowanego nawożenia w Wołczynie i porównując sposób uprawy w Rogowie, następnie przeprowadzić analizę korelacyjną pomiędzy charakterystykami hiperspektralnymi pól uprawnych rejestrowanymi z poziomu lotniczego a właściwościami fizycznymi gleb i stanem fitosanitarnym uprawianych roślin w celu pozyskania uniwersalnych wskaźników hiperspektralnych, a także opracować metodykę wiążącą wertykalne profile strumieni CO₂ z wartościami przypowierzchniowymi emisji tego gazu szklarniowego, w celu sprawdzenia czy istnieje możliwość opracowania sposobu ewaluacji emisji z pól uprawnych z poziomu lotniczego. Wyniki pomiarów i modelowania emisji gazów szklarniowych stały się podstawą do powstania 3 doniesień konferencyjnych **(II.E.26, II.E.36 i II.E.37)**, natomiast w oparciu o opracowane założenia projektu GyroScan powstały 2 doniesienia konferencyjne **(II.E.30, II.E.42)**.

Analiza wpływu zmian klimatu na wzrost, rozwój i plonowanie roślin

Doświadczenia z realizacji projektu *FACCE MACSUR* **(II.I.3)** uzmysłowiły mi doniosłość problemu wpływu zmian klimatycznych na produkcję rolniczą i konieczności adaptacji rolnictwa do tych zmian w celu zapewnienia powszechnego dostępu do żywności. W 2014 roku, w trakcie jednej z konferencji projektowych, została nawiązana współpraca w obrębie szerokiej grupy osób zajmujących się modelowaniem produkcji rolniczej, która postawiła sobie za zadanie zamodelowanie zmian we wzroście, rozwoju i plonowaniu roślin w warunkach zmian klimatycznych prognozowanych na lata 2020-2070. Mając już pewne doświadczenie w modelowaniu produkcji roślinnej zdobyte w trakcie stażu naukowego w Forschungszentrum Jülich **(III.L.1)**, wszedłem w skład tej grupy. Podjąłem decyzję o zastosowaniu w badaniach powszechnie dostępnego, uznanego w środowisku naukowym, oraz niezbyt skomplikowanego i nie potrzebującego dużej ilości danych do kalibracji modelu WOFOST. Głównym założeniem zaproponowanych badań było to, że prognozowane zmiany stężenia CO₂ w atmosferze, a także zmiany takich elementów meteorologicznych jak temperatura czy opad, będą w istotny sposób wpływać na produkcję rolniczą, a to, który czynnik będzie miał decydujące znaczenie, może zależeć od lokalizacji (strefy klimatycznej). Jednym z pierwszych zadań stało się więc wybranie takich lokalizacji, by były one reprezentatywne dla upraw pszenicy w Europie, i by oddawały one jednocześnie zróżnicowanie europejskiego klimatu. Finalnie wybrano 4 lokalizacje różniące się klimatem – Jokioinen w Finlandii, Dikopshof i Nossen w Niemczech oraz Lleidę w Hiszpanii. Scenariusze zmian klimatu tworzone są na podstawie wiedzy o prawach fizycznych rządzących cyrkulacją mas powietrza w skali globalnej z uwzględnieniem procesów determinujących zmiany koncentracji gazów cieplarnianych w atmosferze. Ze względu na fakt, że zarówno stan naszej wiedzy nie jest doskonały, szacunki przyszłych emisji gazów szklarniowych zróżnicowane oraz dane empiryczne obarczone są wieloma niepewnościami, dlatego też

w analizach wpływu zmian klimatu na produkcję roślinną zwykle bierze się pod uwagę zmiany poszczególnych parametrów meteorologicznych w pewnych (dość szerokich) zakresach. Przeprowadzono więc analizę spektrum scenariuszy klimatu dla okresu 2020-2070 i określono możliwe, prognozowane przez te scenariusze dla każdej lokalizacji, zakresy zmian charakterystyk opadu i temperatury. Następnie zarejestrowane dane meteorologiczne z okresu 1981-2010 (zarówno temperaturę, jak i opad) zmodyfikowano poprzez dodanie (lub odjęcie) w sposób systematyczny pewnej wartości z ustalonego wcześniej zakresu. Dzięki temu powstały szeregi czasowe poziomu bazowego (niezmodyfikowane), które posłużyły zarówno do kalibracji modeli, jak i określenia bazowego poziomu produkcji rolnej, oraz szeregi zmodyfikowane, dzięki którym można było zasymulować produkcję rolną odpowiadającą szerokiemu spektrum zmian prognozowanych dla okresu 2020-2070. Takie podejście pozwoliło na zastosowanie metody powierzchni odpowiedzi IRS do analizy uzyskanych wyników. W badaniach wykorzystano wyniki pochodzące od 26 modelarzy posługujących się 24 różnymi modelami. Otrzymane wyniki analizowane były zarówno wykorzystując uśrednianie po zespole (**II.A.3**), jak i analizując powierzchnie odpowiedzi poszczególnych modeli w celu klasyfikowania i rozróżnienia ich odpowiedzi na modyfikacje w seriach czasowych i próbę powiązania regularności z właściwościami modeli wynikającymi z ich konstrukcji i stopnia złożoności (**II.A.5**), czy stworzenia nowego współczynnika EOA (Ensemble Outcome Agreement) analizującego wpływ zmian składu i wielkości zespołu, po którym wykonywane jest uśrednianie, w celu oceny poziomu zgodności między wynikiem uśredniania po zespole, a założoną hipotezą (np.: że plon będzie większy) (**II.A.8**). Z otrzymanych powierzchni odpowiedzi uśrednionych po zespole modeli wynika, że w zakresie badanych zmian temperatury, opadu i koncentracji CO₂, plonowanie pszenicy w Finlandii jest uzależnione w większym stopniu od zmian temperatury niż opadu, natomiast w Niemczech i Hiszpanii wpływ tych czynników na modelowany plon jest bardziej równomierny. Przy ustalonej koncentracji CO₂ w atmosferze zaobserwowano ogólną dla wszystkich lokalizacji tendencję spadku średniej wartości plonu wraz z rosnącą temperaturą i zmniejszającymi się opadami, z kolei zwiększona wartość opadu charakteryzowała się korzystnym wpływem na uzyskiwany plon. Ocieplanie klimatu wpływa na zmiany w plonowaniu w bardzo regularny sposób (redukcja plonu o 5–7% na każdy °C), z kolei zmiany w opadzie powodują mniej stabilną odpowiedź modeli (zmiana plonowania o 1–10% na każdą 10% zmianę intensywności opadu) (**II.A.3**). Zaobserwowano też, że dla poszczególnych modeli wystąpiły znaczne różnice w otrzymywanym plonie, co starano się powiązać z różnicami w ich konstrukcji. W celu klasyfikacji różnic w powierzchniach odpowiedzi poszczególnych modeli zastosowano dwie nowe metody – specjalistycznego podejścia diagnostycznego (Expert Diagnostic Approach, EDA) i statystycznego podejścia diagnostycznego (Statistical Diagnostic Approach, SDA), oferujące alternatywne, uzupełniające się, a w niektórych przypadkach - nakładające się metody klasyfikacji i rozróżniania wzorców modelowanej odpowiedzi na zmiany w seriach czasowych temperatury i opadu. EDA opisuje różne wzorce odpowiedzi posługując się terminami bezpośrednio związanymi z danym oddziaływaniem (np. siła odpowiedzi na zmianę temperatury czy opadu), SDA natomiast jest procedurą bezpośrednią porównywania wzorców odpowiedzi w oparciu o miary statystyczne takie jak metrykę odległości określającą podobieństwo między dwoma wzorami. Ponieważ zastosowane modele charakteryzują się różnym stopniem złożoności, dlatego też nie udało się odnaleźć jednej konkretnej właściwości, która byłaby odpowiedzialna za odpowiedź na zmianę temperatury czy opadu. Udało się jednak

określić, że plon pszenicy ozimej jest mocniej determinowany zmianami w intensywności opadów, niż plon pszenicy jarej, rozróżnić różne siły reakcji modeli na zmiany temperatury i opadów w latach nietypowych w porównaniu do typowych, rozróżnić wpływ warunków klimatycznych (lokalizacji) na wzorce zmian w plonowaniu, wskazując na specyficzną dla każdej lokalizacji kombinację zmian elementów meteorologicznych skutkujących maksymalnym plonem czy jaka jest siła zmian plonu w zależności od stopnia zmian elementów meteorologicznych, a także wskazać podobieństwa we wzorach zmian w plonowaniu przedstawionym za pomocą powierzchni odpowiedzi w przypadku modeli z powiązaną genealogią czy wskazać, że stosowanie modeli z mniej skomplikowanymi modułami odpowiedzialnymi za stres wodny czy opis procesu przyrostu korzeni skutkuje większym podobieństwem w wzorze zmian plonu przedstawionym na IRS (II.A.5). Wyniki opisanych powyżej badań były wielokrotnie prezentowane na konferencjach naukowych i stanowią podstawę wielu doniesień konferencyjnych (II.E.5, II.E.12, II.E.13, II.E.15, II.E.17, II.E.20, II.E.24, II.E.25 oraz II.E.31).

Ocena parametrów fizykochemicznych gleb Polski i jej zasobności w makro- i mikroelementy jako podstawowych czynników determinujących plonowanie w produkcji roślinnej

Od 2014 roku biorę również udział w badaniach środowiskowych i agrochemicznych polegających na przeprowadzeniu analiz i ocenie aktualnego odczynu i zasobności gleb Polski, szczególną uwagę koncentrując na jej południowo-wschodnim rejonie, w podstawowe makro- (N, P, K, Mg, S) i niektóre mikroelementy (B, Cu, Fe, Mn, Zn) oraz określeniu związków tych składników z wybranymi cechami fizykochemicznymi gleb, a także z zabiegami uprawowymi. Przesłanką do podjęcia badań tego typu był fakt, iż właściwości fizykochemiczne gleby są jednym z podstawowych czynników determinujących wzrost i rozwój roślin uprawnych. To od pH gleby (stopnia jej zakwaszenia) oraz zasobności gleby w podstawowe składniki mineralne (na co wpływają zarówno właściwości gleby, jak i zabiegi agrotechniczne, spośród których nawożenie odgrywa najważniejszą rolę) zależy w dużym stopniu wielkość i jakość otrzywanego plonu. Polska jest krajem o znacznym zróżnicowaniu gleb, a tym samym naturalnych warunków produkcji w rolnictwie. Jednym z poważniejszych problemów rolnictwa w Polsce jest zakwaszenie gleb, które wpływa na efektywność nawożenia, co skutkuje albo ograniczeniem wielkości i obniżeniem jakości plonu, albo wymusza zintensyfikowanie nawożenia. W wyniku intensyfikacji obserwuje się silniejsze oddziaływanie użytków rolnych na środowisko przez zanieczyszczenie wód podziemnych i powierzchniowych oraz zwiększoną emisję gazów cieplarnianych. Dodatkowo gleby silnie zakwaszone charakteryzują się niską zawartością magnezu, fosforu, czy molibdenu. Jedną z przyczyn zakwaszania gleb jest niedostosowanie dawek nawozów fizjologicznie kwaśnych do faktycznych potrzeb nawozowych roślin. Dlatego też konieczne jest poszukiwanie rozwiązań optymalizujących gospodarowanie pierwiastkami, w tym azotem, które będą uwzględniały różnorodność gleb Polski. Badania zależności zasobności gleby w składniki pokarmowe, w szczególności azotu, od jej właściwości fizykochemicznych i zabiegów uprawowych mają niezwykle istotne znaczenie utylitarne, ponieważ mogą ułatwić określanie optymalnej dawki nawożenia mineralnego w glebach o zróżnicowanych właściwościach lub przy zróżnicowanym sposobie użytkowania. Ponadto, monitoring podstawowych parametrów fizykochemicznych gleby i jej zasobności w makro- i mikroskładniki prowadzony w skali regionu czy całego kraju może być wykorzystywany w celu oceny zmian zachodzących

w ekosystemach rolnych pod wpływem działalności rolniczej człowieka. W przeprowadzonych badaniach stworzono osobną charakterystykę dla gleb węglanowych, co może stanowić istotny wkład do wprowadzenia korekty do zaleceń nawozowych w warunkach podwyższonej ilości CaCO_3 w warstwie ornej gleby. Z przeprowadzonych badań wynika, że w glebach bezwęglanowych odczyn jest wielkością skorelowaną z kategorią agronomiczną gleby i rośnie wraz z zwiększeniem w niej zawartości cząstek $<0,02$ mm (**II.D.5**, **II.A.4**), z kolei gleby węglanowe nie wykazują takiej zależności (**II.D.5**). Zawartość fosforu w analizowanych próbkach glebowych była dodatkowo skorelowana z kategorią agronomiczną, zawartością materii organicznej i klasą odczynu, a według liczb granicznych analizowane gleby charakteryzowały się wysoką i bardzo wysoką zawartością tego pierwiastka (**II.A.4**). Stwierdzono także jego nieznacznie większą zawartość w glebach węglanowych niż w bezwęglanowych (**II.D.5**). Zawartość potasu była wyraźnie i dodatkowo skorelowana z kategorią agronomiczną, a znacznie słabiej z zawartością materii organicznej i klasą odczynu (**II.A.4**). W glebach węglanowych stwierdzono większą zawartość tego pierwiastka niż w bezwęglanowych, a jego zawartość według liczb granicznych była średnia w obrębie gleb bezwęglanowych, i wysoka w węglanowych (**II.D.5**). Zawartość magnezu przyswajalnego w glebach bezwęglanowych zależała istotnie od kategorii agronomicznej, a jego zasobność w obrębie wszystkich kategorii określić można jako średnią. Zawartość tego pierwiastka zależała również istotnie od klasy odczynu (**II.A.4**). W glebach węglanowych jego zasobność była niska według liczb granicznych, a jedynie gleby ciężkie charakteryzowały się jego znacznie większą zawartością i średnią zasobnością (**II.D.5**). Z kolei zawartość siarki siarczanowej nie zależała od kategorii agronomicznej (**II.A.4**), za to była wyraźnie wyższa w glebach organicznych i zależała od terminu pobierania próbek glebowych (**II.D.6**). Zawartość siarki siarczanowej zależała istotnie i dodatkowo od zawartości przyswajalnych form fosforu w glebie, natomiast całkowita zawartość siarki od występowania węgla organicznego i zasobności gleby w fosfor (**II.D.6**). Z uwagi na nieustanny ubytek siarki w środowisku, szczególne znaczenie miało wykazanie powiązania zawartości siarki siarczanowej z występowaniem przyswajalnych form fosforu i zawartością C_{org} w glebie, co należy uwzględnić w zaleceniach nawozowych przy uprawie roślin wrażliwych na jej niedobory. Badania zawartości mikrośladników wyraźnie wskazują, że gleby bardzo lekkie charakteryzują się znacznie mniejszą zawartością tych pierwiastków, z kolei gleby zasobniejsze w materię organiczną charakteryzują się ich większą zawartością (**II.A.4**). Zastosowano regresję wielokrotną w celu stworzenia modeli zależności badanych mikrośladników (boru, miedzi, żelaza, manganu i cynku) od pozostałych analizowanych właściwości fizykochemicznych gleb. Uzyskane równania, otrzymane dzięki analizie gleb o zróżnicowanych właściwościach, umożliwiają prognozowanie zmian zawartości przyswajalnych form mikroelementów w glebie, tym samym wspomagając rolnika w podejmowaniu decyzji dotyczących nawożenia (**II.A.4**). Przeprowadzono także badania mające na celu ocenę zasobności gleb sadowniczych (głównie sadów jabłoniowych) Polski południowo-wschodniej w makro- i mikroelementy oraz określeniu związków tych składników z wybranymi cechami fizykochemicznymi tych gleb. Badania przeprowadzone były dla rejonu Polski południowo-wschodniej, który jest jednym z największych regionów upraw owocowych w Polsce. W tym celu przeprowadzono analizę składu chemicznego liści jabłoni (**II.D.4**), co pozwoliło stwierdzić, iż odmiana Szampion uprawiana na Lubelszczyźnie była optymalnie zaopatrzona w takie makroelementy jak azot, fosfor, potas, magnez i wapń, a zaopatrzenie w mikroelementy było albo optymalne (bor), albo wystarczające (miedź,

cynk, mangan i żelazo). Przeprowadzono także analizy fizykochemiczne pobranych próbek glebowych (**II.A.6**). Uzyskane wyniki wskazują, iż odczyn większości analizowanych gleb był bliski optymalnemu dla sadów jabłoniowych (czyli był lekko kwaśny). Ponadto, zawartość oznaczanych dostępnych form makro- (P, K, Mg) i mikroelementów (B, Cu, Fe, Mn, Zn) wykazywała istotną i dodatnią korelację zarówno z pH, jak i z klasą agronomiczną.

Wśród ocenianych składników pokarmowych niezwykle istotną rolę odgrywał azot. Jest on nie tylko składnikiem niezbędnym do poprawnego rozwoju roślin, ale stanowi również poważne zagrożenie środowiskowe. Dokonano oceny zawartości azotu amonowego i azotanów(V) w warstwach 0-30, 30-60 i 60-90 cm profilu glebowego i skorelowano te zawartości z wybranymi właściwościami fizykochemicznymi gleby (**II.D.6**). Koncentracja zarówno azotu amonowego, jak i azotanów(V) w glebie była największa w próbkach pobranych z warstwy wierzchniej i zmniejszała się systematycznie w kolejnych warstwach, niezależnie od daty poboru próbek. Zawartość azotu amonowego w warstwie 0-30 cm gleby skorelowana była ze składem granulometrycznym gleby oraz zawartością fosforu, natomiast azotanów(V) – z odczynem i zawartością materii organicznej. Stosowanie wysokich dawek nawożenia azotem może prowadzić do przemieszczania tego składnika w głąb profilu glebowego, zwiększając jego straty i tym samym pogarszając potencjał produkcyjny gleby. Występowanie znacznych stężeń azotu mineralnego w warstwie 60-90 cm profilu glebowego pola upraw stanowi poważne zagrożenie dla jakości wód. Dlatego część badań środowiskowych dotyczących zawartości azotu w glebie stanowiła problematyka jego potencjalnej straty. Dokonano analizy i oceny zawartości azotu w warstwie 60-90 cm i zależności tej zawartości od wybranych czynników naturalnych i antropogenicznych. Analizowano wpływ typu gleby (mineralna lub organiczna), sposobu jej użytkowania oraz intensywności gospodarowania wyrażonej za pomocą rozmiaru produkcji zwierzęcej (**II.D.8**); typu gleby, sposobu jej użytkowania oraz dawki nawożenia azotem mineralnym (**II.A.7**) oraz typu gleby, sposobu jej użytkowania oraz jej odczynu (**II.A.9**). Wykazano, że analizowane czynniki modyfikują występowanie azotu w części profilu glebowego znajdującej się poza zasięgiem głównej masy korzeniowej roślin uprawnych o przeznaczeniu paszowym w różnym stopniu. Niezależnie od okresu prowadzonych badań i ocenianych czynników, to typ gleby jest czynnikiem najsilniej różnicującym zawartość azotu w warstwie 60-90 cm profilu glebowego, a największą tendencją gromadzenia azotu w profilu glebowym na głębokości 60-90 cm wykazywała uprawa kukurydzy, nieznacznie mniejszą – mieszanka zbożowa, natomiast najmniejszą zawartością azotu charakteryzowały się gleby mineralne użytków zielonych. Otrzymane wyniki sugerują, iż istnieje zależność pomiędzy rozmiarami produkcji zwierzęcej a zawartością azotu mineralnego w ocenianej warstwie gleby, jednak rodzaj tej zależności zależy zarówno od sposobu użytkowania gruntów, jak i terminu poboru próbek glebowych. Wykazano także, że zarówno dawka nawożenia azotem mineralnym, jak i odczyn gleby wywierał istotny wpływ na zawartość azotu na głębokości 60-90 cm w profilu glebowym gleb mineralnych, niezależnie od terminu poboru próbek czy sposobu użytkowania. Otrzymane korelacje pomiędzy pH a zawartością N_{\min} oraz pomiędzy dawką nawożenia a zawartością N_{\min} były dodatnia. Dla gleb organicznych otrzymane zależności nie są jednoznaczne. Przeprowadzono badania środowiskowe dla regionu Lubelszczyzny wpływu niektórych właściwości fizykochemicznych gleby i nawożenia azotem na plon pszenicy ozimej (**II.D.7**). W analizie uwzględniono wpływ trzech poziomów nawożenia (0-30; 30-60 i 60-90 kg N/ha). Wyniki jednoznacznie wskazują, iż nawożenie pszenicy ozimej azotem zwiększa znacząco plon, a pod

wpływem najwyższej analizowanej dawki wzrasta o 82,5% w stosunku do dawki najmniejszej. Na plon miał także wpływ odczyn gleby oraz jej gatunek. Najwyższy plon otrzymano na glebach o odczynie obojętnym i zasadowym oraz charakteryzującej się dużą ilością frakcji pyłowej.

Wyniki przeprowadzonych badań środowiskowych prezentowane były na **2** konferencjach, w wyniku czego powstały dwa doniesienia konferencyjne (**II.E.18** oraz **II.E.47**).

Ocena właściwości wodnych gleb mineralnych Polski na podstawie ich charakterystyk spektralnych

W latach 2015-2017 byłem promotorem pomocniczym przewodu doktorskiego mgr Joanny Pastuszki-Woźniak (**III.K.1**). Wraz z doktorantką, a także z promotorem prof. dr hab. Piotrem Baranowskim, prowadziliśmy badania, których celem było opracowanie modeli wilgotności gleby i potencjału wody glebowej na podstawie charakterystyk spektralnych powierzchni gleby i jej właściwości fizykochemicznych. W badaniach zastosowaliśmy metodę regresji wielokrotnej, która umożliwiła oszacowanie zmienności jednej zmiennej zależnej (wilgotności gleby lub potencjału wody glebowej) za pomocą zespołu zmiennych niezależnych (danych spektralnych i wybranych właściwości gleb). Wynikiem zastosowania regresji wielokrotnej było utworzenie modeli umożliwiających predykcję wilgotności gleby (bądź potencjału wody glebowej). Opracowaliśmy także metodę optymalnej reguły przydzielającą próbkę gleby do z góry zdefiniowanych klas (np. określonej wartości potencjału w zależności od zmierzonej wilgotności próbki), korzystając z różnych metod klasyfikacji nadzorowanej. Doktorat pt. *Ocena zdolności retencyjnej gleb na podstawie ich charakterystyk spektralnych* zakończył się publiczną obroną w dniu 26.05.2017 r., a praca doktorska otrzymała wyróżnienie. Uzyskane doświadczenie wykorzystuję w obecnie realizowanym projekcie GyroScan (**II.I.7**), który finansowany jest w ramach strategicznego programu badań naukowych i prac rozwojowych „Środowisko naturalne, rolnictwo i leśnictwo” BIOSTRATEG, w celu powiązania charakterystyk hiperspektralnych pól uprawnych rejestrowanych z poziomu lotniczego z właściwościami fizycznymi gleb i stanem fitosanitarnym uprawianych roślin.

6. Podsumowanie dorobku naukowego:

Mój dorobek publikacyjny obejmuje łącznie **85** pozycji:

- **27** oryginalnych prac twórczych (**20** po uzyskaniu stopnia naukowego doktora), w tym **21** w czasopiśmie posiadających IF (**15** po uzyskaniu stopnia naukowego doktora),
- **4** rozdziały w monografiach,
- **54** komunikaty konferencyjne (**50** po uzyskaniu stopnia naukowego doktora).

Sumaryczna liczba punktów przypisanych pracom naukowym, których jestem autorem lub współautorem, zgodnie z punktacją MNiSW w poszczególnych latach wydania publikacji, wynosi **656** (**588** prac opublikowanych po doktoracie, **68** prac opublikowanych przed doktoratem), a sumaryczny współczynnik wpływu Impact Factor (IF) w roku wydania prac wynosi **35,597** (**32,01** prac opublikowanych po doktoracie, **3,587** prac opublikowanych przed doktoratem). Szczegółowy wykaz opublikowanych prac naukowych wraz z przypisanymi im punktami wg wykazu czasopism naukowych MNiSW zgodnie z rokiem opublikowania oraz współczynnikiem wpływu IF zawarty jest w tabelach 1-3. Liczba cytowań według bazy Web of Science

Core Collection wynosi **171**, a indeks Hirscha według bazy Web of Science Core Collection wynosi **9**.

Brałem udział w **28** konferencjach naukowych, warsztatach, seminariach lub szkołach letnich (w tym w **19** po uzyskaniu stopnia naukowego doktora), m.in. w tak prestiżowych jak International work-conference on Time Series (ITISE 2016) w Granadzie, 3rd International Conference on Global Food Security w Kapsztadzie, czy w **5** dużych konferencjach organizowanych w ramach FACCE MACSUR. Wygłosiłem **7** referatów na konferencjach międzynarodowych lub krajowych, w tym **4** w języku angielskim oraz **3** w języku polskim. Jestem autorem (lub współautorem) **37** referatów wygłoszonych na konferencjach międzynarodowych i krajowych oraz **33** posterów. Ponadto wygłosiłem **4** referaty na zaproszenie, w tym **1** po angielsku w Dreźnie i **1** popularnonaukowy.

W ciągu całego okresu pracy zawodowej brałem czynny udział w realizacji **11** projektów badawczych, we wszystkich będąc wykonawcą projektu. Brałem udział w europejskim projekcie MACSUR "Modelowanie Europejskiego Rolnictwa ze Zmianami Klimatu dla Bezpieczeństwa Żywności" w ramach Centrum Wiedzy FACCE JPI, którego celem było modelowanie wybranych aspektów europejskiego rolnictwa w różnych scenariuszach zmian klimatu w celu zapewnienia bezpieczeństwa żywnościowego w Europie i na świecie, a także stworzenie ogólnoeuropejskiej platformy badań i rozwoju umożliwiającej wykorzystywanie i interpretację modeli do określenia oceny ryzyka wpływu zmian klimatu na rolnictwo europejskie. Brałem lub biorę także udział w realizacji **4** projektów finansowanych ze strategicznego programu badań naukowych i prac rozwojowych „Środowisko naturalne, rolnictwo i leśnictwo” BIO-STRATEG. Byłem lub jestem członkiem **5** konsorcjów lub sieci badawczych i brałem udział w **4** programach europejskich, międzynarodowych lub krajowych.

Odbyłem staż naukowy w Institute of Bio- and Geosciences Agrosphere (IBG-3), Forschungszentrum Jülich w Niemczech, a także byłem opiekunem naukowym stażu *Wpływ nawożenia na właściwości fizykochemiczne gleb mineralnych Polski* w Zakładzie Metrologii i Modelowania Procesów Agrofizycznych Instytutu Agrofizyki im. Bohdana Dobrzańskiego PAN dr inż. Przemysława Tkaczyka z Katedry Chemii Rolnej i Środowiskowej Uniwersytetu Przyrodniczego w Lublinie.

W latach 2015-2017 pełniłem rolę promotora pomocniczego w przewodzie doktorskim mgr Joanny Pastuszki-Woźniak pt. *Ocena zdolności retencyjnej gleb na podstawie ich charakterystyk spektralnych / Evaluation of soil retention capacity based on its spectral characteristics*, a 27.04.2018 r. zostałem powołany na promotora pomocniczego przewodu doktorskiego mgr inż. Magdaleny Gos pt. *Prognozowanie wielkości elementów meteorologicznych i określanie multifraktalności ich szeregów czasowych dla różnych stref klimatycznych w Europie / Forecasting of meteorological elements and determination of multifractality of their time series for various climatic zones in Europe*. Głównym celem realizowanej przez magistrantkę pracy doktorskiej jest ocena jakości predykcji wybranych wielkości meteorologicznych wyznaczonych z wykorzystaniem modeli statystycznych oraz określanie właściwości multifraktalnych szeregów czasowych tych wielkości dla różnych stref klimatycznych w Europie. W ramach doktoratu zajmujemy się predykcją wielkości agrometeorologicznych z wykorzystaniem klasycznych metod statystycznych i wybranych metod sztucznej inteligencji oraz określeniem właściwości multifraktalnych szeregów czasowych wielkości meteorologicznych w skali kraju

(korzystając z danych pochodzących ze stacji synoptycznych IMGW) oraz kontynentu (wykorzystując dane pochodzące z bazy MERRA-II).

Od 2009 roku wykonałem **23** recenzje artykułów naukowych dla **10** czasopism o zasięgu międzynarodowym, m.in. dla tak prestiżowych jak Biogeosciences, Agricultural and Forest Meteorology czy Chaos, Solitons & Fractals.

Za działalność naukową w okresie 2015-2018 r. otrzymałem **6-krotnie** nagrodę Dyrektora Instytutu Agrofizyki im. Bohdana Dobrzańskiego Polskiej Akademii Nauk.

Tabela 1. Zestawienie dorobku według rodzaju publikacji

Rodzaj publikacji	Liczba publikacji	Suma punktów wg wykazu czasopism naukowych MNiSW zgodnie z rokiem opublikowania	Sumaryczny IF
Czasopisma ze współczynnikiem wpływu IF, wyróżnione w Journal Citation Reports (lista A)	21	563	35,597
Czasopisma bez współczynnika wpływu IF (lista B)	6	63	–
Rozdziały w monografiach naukowych w języku polskim	3	15	–
Rozdziały w monografiach naukowych w języku angielskim	1	15	–
Materiały konferencyjne	54	–	–
W SUMIE:	85	656	35,597
– w tym osiągnięcie	7	245	16,335
- w tym pozostały dorobek (bez osiągnięcia)	78	411	19,262
– w tym po doktoracie (z osiągnięciem)	74	588	32,01
– w tym po doktoracie (bez osiągnięcia)	67	343	15,675
- w tym przed doktoratem	11	68	3,587

Tabela 2. Zestawienie dorobku naukowego według udziału habilitanta w publikacji

Rodzaj publikacji	Pierwszy autor lub autor korespondencyjny	Drugi autor	Trzeci lub dalszy autor	Razem
Oryginalne prace twórcze	15	3	9	27
Monografie lub rozdziały w monografiach	1	1	2	4
W SUMIE	16	4	11	31

Tabela 3. Zestawienie dorobku naukowego według tytułów czasopism naukowych

Lp.	Tytuł	Liczba publikacji	Suma punktów wg wykazu czasopism naukowych MNiSW zgodnie z rokiem opublikowania	Sumaryczny IF
1	Acta Agrophysica	5	63	–
2	Acta Physica Polonica A	3	36	1,255
3	Acta Physica Superficerum	1	–	–
4	Agricultural and Forest Meteorology	3	135	12,117
5	Agricultural Systems	2	100	6,008
6	Applied Ecology and Environmental Research	1	15	0,721
7	Climate Research	2	70	3,38
8	International Agrophysics	2	50	2,484
9	Journal of Elementology	1	15	0,684
10	Journal of Physics: Condensed Matter	1	32	2,332
11	Journal of Physics: Conference Series	2	–	–
12	Measurement	1	30	1,484
13	Przemysł Chemiczny	1	15	0,399
14	Theoretical and Applied Climatology	1	30	2,321
15	Vadose Zone Journal	1	35	2,412
16	Rozdziały w monografiach	4	30	–
W SUMIE		31	656	35,597

Lublin, 25.04.2019 r.