



## BIOINDYKACJA + CHEMOMETRIA = ?

Karolina Astel, Politechnika Gdańska, Wydział Chemiczny, Katedra Chemii Analitycznej

Aleksander Astel, Pomorska Akademia Pedagogiczna, Instytut Biologii i Ochrony Środowiska,  
Zakład Chemii Środowiskowej

### Wprowadzenie

W ciągu ostatnich dziesięcioleci rozwinęła się technika badania depozycji pierwiastków z atmosfery w oparciu o wykorzystanie faktu, że rośliny mogą absorbować pierwiastki oraz adsorbować cząstki stałe z mokrej i suchej depozycji. Wykorzystanie mchu jako biowskaźnika jest dogodnym sposobem określania depozycji atmosferycznej ze względu na fakt, że zdecydowana większość przyswajanych przez mech pierwiastków pochodzi właśnie z tego źródła. Istnieje obszerne studium literaturowe poświęcone wykorzystaniu takich gatunków jak np.: *Pleurozium shreberi* [1–4], *Hylocomium splendens* [1,3,4], *Scleropodium purum* [1,5], *Abietinella abietina* [1], *Hypnum cupressiforme* [6], *Bryum radiculosum* [7] czy *Rhytidiadelphus squarrosus* [8] w badaniu depozycji pierwiastków, w tym metali ciężkich.

W badaniach wykorzystano mech torfowiec (*Sphagnum pallustre*) jako biowskaźnik zawartości zanieczyszczeń obecnych w powietrzu atmosferycznym aglomeracji gdańskiej w trakcie półrocznej ekspozycji.

Obszar badań w postaci dwunastu wybranych dzielnic mieszkaniowych znajduje się w bliskim sąsiedztwie głównych emiterów zanieczyszczeń zlokalizowanych na terenie Gdańska. W większości są to zakłady uznane przez Wojewódzkiego Inspektora Ochrony Środowiska [9] za uciążliwe dla środowiska. W pobliżu rejonu objętego badaniami występuje ponadto szereg mniejszych emiterów zanieczyszczeń, jak np.: warsztaty samochodowe, szlaki komunikacyjne o dużym natężeniu ruchu pojazdów osobowych i ciężarowych, zabudowa mieszkaniowa.

W celu przeprowadzenia eksperymentu skonstruowano stanowiska pomiarowe, w których umieszczono mech torfowiec w doniczkach przystosowanych do hodowli hydroponicznej, jak również w otwartych koszach. Badania porównawcze prowadzono w warunkach rzeczywistych, co stanowi jedną z zalet projektu. Zaproponowana metoda rozpoznawania stanu zanieczyszczenia powietrza atmosferycznego oraz określania źródeł tego zanieczyszczenia na podstawie znanych profili pierwiastkowych poszczególnych gałęzi przemysłu jest relatywnie łatwa i tania.



Rys. 1. Rozmieszczenie stacji badawczych oraz potencjalnych emiterów zanieczyszczeń powietrza na terenie Gdańska; na wykresie w postaci róży wiatrów przedstawiono kierunki przeważające w trakcie półrocznego okresu badań (06–11.2003).

W ramach niniejszego opracowania przedstawiono metodykę postępowania prowadzącego do rozwiązania sformułowanego problemu badawczego oraz określono korzyści, jakie przynosi badaczowi poprawne wykorzystanie metod analizy danych do weryfikacji postawionych pytań czy hipotez badawczych. Szczegółowy opis projektu przedstawiono w rozprawie doktorskiej: „Monitoring nieorganicznych zanieczyszczeń atmosfery Gdańska w oparciu o wykorzystanie mchu *Sphagnum palustre* jako biowskaźnika”, dostępnej w czytelni Biblioteki Głównej Politechniki Gdańskiej.

## Hipotezy postawione w pracy

***Hipoteza nr 1: Pomiar zawartości analitów, będących po części zanieczyszczeniami atmosferycznymi, w badanym gatunku mchu (*Sphagnum palustre*), przed i po określonym czasie ekspozycji, może służyć do oceny stopnia zanieczyszczenia powietrza atmosferycznego na obszarach miejskich.***

Aby mech *Sphagnum palustre* spełniał wymagania stawiane bioindykatorowi, musi charakteryzować go:

1. powszechna dostępność o każdej porze roku;
2. wytrzymałość na zmienne warunki pogodowe;
3. niski koszt i łatwość pobierania próbek;



4. możliwość powiązania depozycji zanieczyszczeń z zawartością analitów w tkance roślin ze względu na krótki czas odpowiedzi na zmiany w chemicznym składzie środowiska oraz zdolności adaptacyjne – kumulacja zanieczyszczenia środowiska.

Zgodność pierwszych trzech cech z wymaganiami zweryfikowano na podstawie danych literaturowych [10–13] dotyczących morfologii i fizjologii *Sphagnum palustre*, zaś ostatnią cechą charakterystyczną należało zbadać na drodze eksperymentalnej.

### ***Hipotezę zweryfikowano, realizując następujące cele badawcze:***

1. Zbadano stopień kumulacji zanieczyszczeń nieorganicznych w mchu torfowcu.
2. Po półrocznym okresie ekspozycji w stosunku do wartości bazowych (poziomu naturalnego tła) – pomiar zawartości analitów w próbkach mchu z wykorzystaniem neutronowej analizy aktywacyjnej w Badawczym Reaktorze Jądrowym w Delft, Holandia (Politechnika Delfijska).
3. Porównano efektywność dwóch form biomonitoringu aktywnego (z wykorzystaniem zarówno mchu martwego, jak i utrzymywanego przy życiu) w ocenie zanieczyszczenia powietrza atmosferycznego (ekspozycja materiału roślinnego w specjalnych pojemnikach).

### ***Hipoteza nr 2: Metody chemometryczne usprawniają wnioskowanie na bazie wyników generowanych podczas badań bioindykacyjnych.***

Rosnący zakres zastosowań technik chemometrycznych do optymalizacji metod eksploracji i modelowania wyników pochodzących z monitoringu środowiska wymusił powszechne wprowadzenie chemometrii do badań naukowych. W związku z tym postanowiono zweryfikować efektywność wybranych technik chemometrycznych w analizie danych uzyskanych na podstawie badań analitycznych materiału biologicznego – próbek żywego oraz suchego mchu torfowca. Porównywano techniki oparte na zasadach logiki klasycznej oraz rozmytej.

### ***Hipotezę zweryfikowano, realizując następujące cele badawcze:***

1. Na podstawie profili pierwiastkowych rozpoznano oraz zidentyfikowano źródła zanieczyszczenia powietrza atmosferycznego w dwunastu osiedlach gdańskich.
2. Rozpoznano zależności pomiędzy poszczególnymi analitami tworzącymi zanieczyszczenia atmosferyczne oraz warunkami klimatycznymi, a przede wszystkim kierunkami wiatrów przeważającymi w czasie ekspozycji.

### ***Jak i dlaczego chemometria usprawniła proces wnioskowania – wybrane elementy analizy wyników***

Przed przystąpieniem do właściwych analiz chemometrycznych należy wykonać żmudny, aczkolwiek niezbędny proces właściwego przygotowania danych. Poprawne wykonanie kontroli danych jest gwarantem uzyskania miarodajnych i możliwych do interpretacji wyników.



W pierwszym etapie dokonano selekcji danych eksperymentalnych na podstawie oceny wyników wykonanych pomiarów chemicznych. Określono zdolność zastosowanej techniki analitycznej do oznaczenia zawartości analitów w próbkach poddanych analizie. Pierwiastki, w przypadku których podejrzewano wynik oznaczeń obarczony znaczną niepewnością, wykluczono z dalszej analizy. Przykładowo jeśli uzyskana wartość stężenia była niższa lub bliska granicy oznaczalności wyznaczonej dla danego pomiaru, wynik usuwano z zestawu danych, a w skrajnych przypadkach zastępowano wartością równą połowie granicy oznaczalności zastosowanej techniki analitycznej [14].

Kolejnym krokiem kontroli danych było sprawdzenie wielkości stężeń poszczególnych pierwiastków dla porównywanych próbek i wykluczenie z dalszego toku analizy zmiennych o zbyt niskiej wartości rozstępu jako niewnoszących informacji pomocnej w ocenie zróżnicowania punktów pomiarowych. Porównano wyniki dla zbioru danych przed wykluczeniem tych o małej zmienności z wynikami dla zbioru po ich wykluczeniu, aby ustalić, czy nie usunięto zmiennej mającej znaczący wpływ na wynik analizy.

Kolejną redukcję zmiennych dokonano na podstawie porównania współczynników korelacji, które z założenia odzwierciedlają ogólny obraz zależności i podobieństw w badanym zestawie danych. Uwzględniono ponadto profile pierwiastkowe potencjalnych źródeł zanieczyszczeń i wykorzystano je w analizie danych, aby zweryfikować, czy zawierają wystarczającą do analizy chemometrycznej ilość informacji, pozwalającej na uzyskanie miarodajnych i interpretowalnych wyników, co pozwoliło by w przyszłości zredukować czas i koszt badań bez utraty istotnych informacji.

Redukcja części zmiennych doprowadziła do zwiększenia stopnia symetrii macierzy danych wejściowych [15,16]. Po wykluczeniu części zmiennych z zestawu danych przygotowano arkusz wejściowy do pakietu *STATISTICA*. Dane standaryzowano zgodnie z tzw. transformacją „z”, aby „neutralizować” wpływ różnic w rzędach wielkości oznaczonych stężeń analitów na wyniki analiz chemometrycznych.

Oprócz ogólnie znanych metod chemometrycznych opartych na zasadach logiki klasycznej zastosowano również metody oparte na zasadach logiki rozmytej z wykorzystaniem aplikacji *Sadic*<sup>®</sup>, udostępnionej dzięki uprzejmości profesora Costela Sârbu z Katedry Chemii Analitycznej Wydziału Chemii i Inżynierii Chemicznej Uniwersytetu Babeş-Bolyai w Cluj-Napoca w Rumunii. Proces wizualizacji wyników uzyskanych za pomocą ww. aplikacji przeprowadzono z wykorzystaniem pakietu *STATISTICA* ze względu na ograniczone możliwości aplikacji *Sadic*<sup>®</sup>.

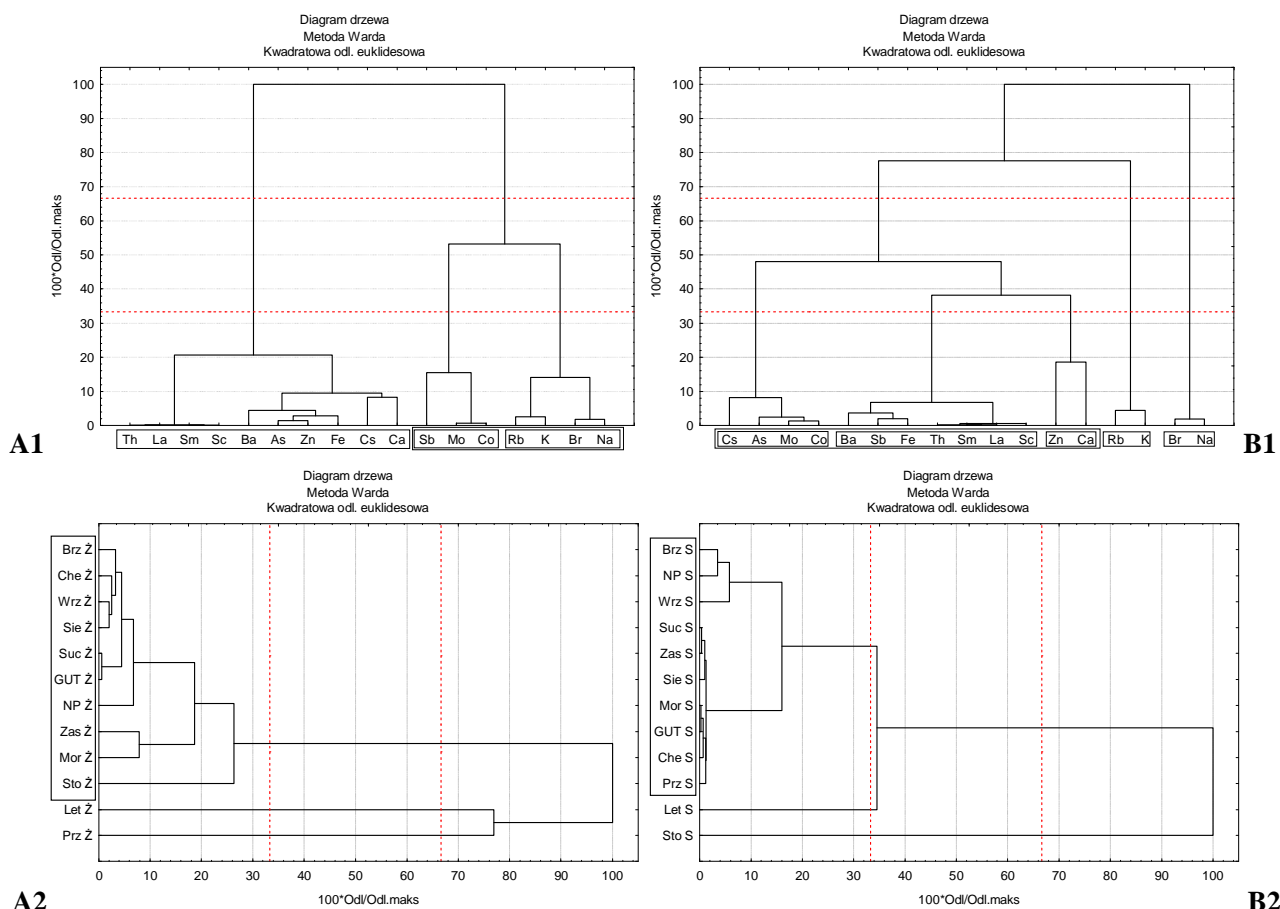
## Wnioskowanie klasyczne

### *Analiza wiązkowa*

Podczas konfigurowania opcji analizy wiązkowej zdecydowano się zastosować algorytm Warda tworzenia skupień oraz kwadrat odległości euklidesowej jako miarę podobieństwa. Istotność klastrow w dendrogramie hierarchicznym określono na podstawie dwóch

poziomów indeksu Sneath'a, czyli odpowiednio: 33,3 % i 66,7 % maksymalnej odległości ( $Odl_{max}$ )[17].

Zastosowanie analizy wiązkowej doprowadziło do wykazania, że suchy i żywy mech torfowiec *Sphagnum palustre* wykazuje odmienne zdolności biokumulacyjne, a co za tym idzie bioindykacyjne. Ponadto wyodrębniono klastry grupujące pierwiastki wskazujące na profile pierwiastkowe odpowiadające pewnym aktywnościom antropogenicznym (np. produkcja nawozów fosforowych, spalanie paliw w celu pozyskiwania ciepła czy emisja związana z transportem kołowym) i procesom naturalnym (np. pył i bliskość morza). Wyniki analizy wiązkowej przedstawiono na poniższych diagramach.



Rys. 2. Wyniki analizy wiązkowej dla mchu suchego (odpowiednio A1 i A2) i żywego (B1 i B2).


Wyodrębnione punkty odbiegające, których odmiennosć, rozumiana jako stopień zanieczyszczenia atmosfery, jest prawdopodobnie skorelowana z przeważającymi kierunkami wiatrów oraz z położeniem geograficznym wyodrębnionych stanowisk względem głównych emiterów zanieczyszczeń powietrza. Letnica i Przeróbka to stacje położone najbliżej zakładów nawozów fosforowych, portów i stoczni, a w związku z tym, wpływ przemysłu na zanieczyszczenie powietrza w tych punktach pomiarowych powinien być najbardziej istotny. Mając a uwadze przeważające kierunki wiatrów (NW i W), występujące w trakcie ekspozycji mchu, Stogi wydają się znajdować pod tym samym wpływem. Wiatry

południowo-wschodnie nie wpływają na skład pierwiastkowy próbek mchu eksponowanych w stacjach umieszczonych w dzielnicach: Nowy Port i Brzeźno.


Może to wynikać z faktu, że teren Nowego Portu charakteryzuje zmienna cyrkulacja wiatru spowodowana bliskością morza. Zanieczyszczenia mogą być więc przenoszone do stacji położonych w większej odległości od morza, np. Letnicy. W przypadku Brzeźna istotną rolę może odgrywać znaczna odległość od zakładów nawozów fosforowych.

### ***Analiza głównych składowych***

W celu zwalidowania wyników przeprowadzonej analizy wiązkowej oraz lepszego poznania uzyskanych zależności zastosowano analizę głównych składowych w opcji z normalizowaną rotacją Varimax do zbioru danych standaryzowanych. Wyniki analizy głównych składowych przedstawiono na poniższych diagramach 3D.





mech suchy



mech żywy

PCA




Wyodrębniono kilka statystycznie istotnych składowych głównych, którym na podstawie profili pierwiastkowych przyporządkowano następnie interpretację chemiczną zgodną ze źródłem emisji. Zauważa się występowanie wyraźnej różnicy między dwoma bio wskaźnikami, polegającą na zróżnicowanej odpowiedzi mchu na przyswajane pierwiastki w zależności od tego, czy jest to roślina żywa, czy jedynie materiał pochodzenia roślinnego.

## Wnioskowanie rozmyte

### Wprowadzenie do teorii wnioskowania rozmytego

Złożoność danych rzeczywistych sprawia, że wnioskowanie oparte na dwuwartościowej logice Arystotelesa (prawda/fałsz; tak/nie) oraz klasycznie pojmowanych zbiorach (ang. *crisp sets*) nie daje możliwości rozwiązania wielu sprzeczności i niejednoznaczności. Znane i stosowane wcześniej metody matematyczne, wykorzystujące klasyczną teorię zbiorów i logikę dwuwartościową, okazały się nie być wystarczająco efektywne w rozwiązywaniu problemów, z jakimi radzą sobie obecnie systemy rozmyte [18]. Niezbędne okazuje się więc zaangażowanie w tok analiz tzw. wnioskowania rozmytego, które jest oparte na regułach logiki rozmytej (ang. *fuzzy logic*) zaproponowanej przez Lofti Zadeha [19] z Uniwersytetu w Teheranie w 1965 roku i stanowiącej jedną z logik wielowartościowych (ang. *multi-valued logic*). Logika rozmyta jest ściśle powiązana z teorią zbiorów rozmytych i teorią prawdopodobieństwa. W logice rozmytej między stanem 0 (fałsz; nie) a stanem 1 (prawda; tak) istnieje szereg wartości pośrednich, które można kojarzyć z prawdopodobieństwem. Aby lepiej zobrazować różnice między wnioskowaniem klasycznym i rozmytym poniżej przedstawiono przykład – podział ludzi według wieku. Przeprowadzenie ankiety dotyczącej podziału na grupy wiekowe wykaze, że przedziały podane przez różne osoby nie będą ostre, ale właśnie rozmyte [20].



Rys. 3. Przykład wnioskowania opartego na regułach logiki klasycznej (z lewej) i na regułach logiki rozmytej (z prawej) [21].

Zakładając, że większość kategorii wyodrębnianych za pomocą analizy podobieństwa ma niewyraźne granice i może charakteryzować się współzależnością, oczywista staje się potrzeba zastosowania systemów rozmytych. Odpowiednikiem klasycznej analizy wiązkowej w przypadku systemów rozmytych jest rozmyta metoda analizy wiązkowej (FCA – ang. *fuzzy clustering*). Natomiast odpowiednikiem klasycznej analizy głównych składowych, stosowanym w systemach rozmytych, jest rozmyta analiza głównych składowych (FPCA, ang. *fuzzy principal components analysis*) [20].

W rozmytej metodzie analizy wiązkowej zgodnie z wyborem prototypu klastra (środka klastra) i miary odległości punktu od prototypu określa się różne algorytmy rozmytej analizy wariacji. Jeśli prototyp jest punktem, powstaną klastry sferyczne; jeśli jest linią prostą, powstaną klastry walcowe, itd. Elementy o dużym stopniu przynależności do klastra, czyli bliskie środka klastra, będą znacząco wpływać na średnią ważoną, podczas



gdy elementy o małym stopniu przynależności, odległe od środka klastra, nie będą miały w niej istotnego udziału [21,22].

Algorytm analizy głównych składowych z rozmytą składową pierwszą (FPCA1 – ang. *fuzzy first component PCA*) opisali wcześniej Sârbu i Pop [22–24]. Określa się taki stopień przynależności punktów, dla którego pierwsza składowa główna jest najlepiej dopasowana do zawartości macierzy danych  $X$  [22–24]. Wyznacza się optymalne wartości stopni przynależności i na ich podstawie tworzy się macierz kowariancji lub korelacji, wykorzystując ponadto średnią arytmetyczną dla danej zmiennej oraz współczynnik rozmycia ( $>1$ ). Następnie wyznacza się wartości i wektory własne (ang. *eigenvalues*, *eigenvectors*), stanowiące rozmyte składowe główne i odpowiadające im współrzędne [22–24]. W algorytmie analizy głównych składowych z rozmytą składową pierwszą wektory własne powstają w wyniku rozmywania pierwszej składowej głównej, podczas gdy pozostałe składowe nie są rozmywane.

W algorytmie ortogonalnej rozmytej analizy głównych składowych (FPCAO – ang. *orthogonal fuzzy PCA*) pierwotny zestaw danych jest rzutowany na hiperpłaszczyznę ortogonalną do pierwszej rozmytej składowej głównej, to jest określoną przez pozostałe główne składowe zgodnie z algorytmem zastosowanym dla analizy głównych składowych z rozmytą składową pierwszą. Można to osiągnąć, obliczając wartości czynnikowe (ang. *scores*), a następnie usuwając pierwszą składową główną. W ten sposób otrzymuje się zestaw danych w przestrzeni euklidesowej o wymiarze  $p-1$ , gdzie  $p$  jest wymiarem pierwotnego zestawu danych. Pierwsza składowa główna rzutowanego zbioru danych, po transformacji w stosunku do pierwotnej przestrzeni danych, jest ortogonalna do pierwszej składowej głównej, otrzymanej przed transformacją [22-24]. Wyznaczenie trzeciej składowej głównej odbywa się analogicznie do sposobu wyodrębniania składowej drugiej, przy czym zaczyna się od rzutowanego wcześniej zestawu danych, który rzutuje się na hiperpłaszczyznę ortogonalną do pierwszych dwóch rozmytych głównych składowych. Taki podwójnie rzutowany zestaw danych będzie się znajdował w przestrzeni euklidesowej o wymiarze  $p-2$  [22-24]. Ostateczna transformacja obejmuje odwrócenie uzyskanych wartości i wektorów własnych do pierwotnej przestrzeni o wymiarze  $p$  [22-24].

### **Rozmyta analiza wiązkowa**

Zastosowano rozmytą hierarchiczną analizę wiązkową z prototypami punktowymi (ang. *fuzzy hierarchical clustering with point prototypes*) do klasyfikacji punktów pomiarowych, na podstawie podobieństw między wynikami oznaczeń analitycznych. Wyodrębniono więcej grup oraz punktów odbiegających w porównaniu z klasyczną analizą wiązkową opisaną wcześniej. Wyniki rozmytej analizy wiązkowej przedstawiono poniżej.

Rozmyta analiza wiązkowa okazała się bardziej skuteczna od klasycznej, zwłaszcza w przypadku grupowania wyników uzyskanych dla próbek mchu żywego. Wyodrębniono logiczny i przejrzysty podział na klasy. Pierwszy stopień klasyfikacji przedstawia podział na stacje będące i niebędące pod wpływem zanieczyszczeń wytwarzanych w przemysłowej części miasta – Stogi, Przeróbka oraz Letnica są znacznie bardziej obciążone ładunkiem



zanieczyszczeń atmosferycznych niż pozostałe stacje. Kolejny stopień pozwala rozróżnić wpływ poszczególnych profili zanieczyszczeń.

### MECH SUCHY

*Klasa → Element*

- 1. → Stogi
- 2.1. → Brzeźno, Nowy Port, Letnica,  
Wrzeszcz
- 2.2.1.1. → Zaspa
- 2.2.1.2. → Suchanino, Siedlce
- 2.2.2.1. → Wrzeszcz-PG
- 2.2.2.2.1. → Chełm
- 2.2.2.2.2. → Morena, Przeróbka

### MECH ŻYWY

*Klasa → Element*

- 1.1. → Brzeźno, Nowy Port, Zaspa, Morena,  
Siedlce
- 1.2. → Suchanino, Chełm, Wrzeszcz,  
Wrzeszcz-PG
- 2.1. → Stogi, Przeróbka
- 2.2. → Letnica


### ***Rozmyta analiza głównych składowych***

Przed wykonaniem rozmytej analizy głównych składowych dane standaryzowano. Grupowanie przypadków w wyniku analizy głównych składowych, z rozmywaniem jednej bądź wszystkich składowych głównych, odpowiada wynikom uzyskanym wcześniej w toku rozmytej analizy wiązkowej.


Grupowanie analitów w rozmytej analizie głównych składowych jest zbliżone do tego, które zaobserwowano w toku klasycznej analizy głównych składowych. Wyodrębnione składowe główne można zinterpretować analogicznie do tych, które określono na podstawie przeprowadzonych analiz bazujących na prawach logiki klasycznej, a mianowicie: „nawozy fosforowe” jako główne źródło zanieczyszczenia powietrza wywierające wpływ na badany obszar, „morze”, „miasto” i „pył” jako kolejne źródła zdefiniowane jako istotne zarówno w badaniu stopnia kumulacji analitów w mchu żywym, jak i suchym, oraz „cykl życiowy rośliny” występujący w przypadku wykorzystania mchu żywego jako bio wskaźnika.

Udział poszczególnych pierwiastków w profilach wydaje się bardziej „rozmyty” niż w przypadku klasycznego grupowania, jednak taki obraz jest logiczny, ponieważ dany pierwiastek może być istotny w przypadku więcej niż tylko jednego profilu.

Na poniższych diagramach 3D przedstawiono układ danych w przestrzeni uzyskany w toku analizy głównych składowych z rozmytą pierwszą składową główną oraz w toku ortogonalnej rozmytej analizy głównych składowych.




mech suchy




mech żywy

FPCA1







mech suchy



mech żywy

FPCA0





## Podsumowanie i wnioski

Zastosowanie technik chemometrycznych do identyfikacji źródeł zanieczyszczeń pozwala powiązać dane uzyskane w wyniku analiz składu chemicznego próbek z przeważającymi kierunkami wiatrów. Zastosowanie chemometrii pozwala ponadto zredukować przyszły koszt biomonitoringu kontynuowanego na badanym obszarze przez optymalizację procedury badawczej, czego skutkiem jest redukcja ilości niezbędnych analitów oraz stacji badawczych bez utraty informacji na temat stanu zanieczyszczenia atmosfery na badanym terytorium.

Na podstawie chemometrycznej analizy danych wyodrębniono nie tylko profile składające się łącznie z 17 pierwiastków (Na, K, Ca, Sc, Fe, Co, Zn, As, Br, Rb, Mo, Sb, Cs, Ba, La, Sm i Th), ale również zredukowaną ilość stacji monitoringowych reprezentujących obszary znajdujące się pod wpływem poszczególnych profili. W przypadku stosowania żywego biowskaźnika wystarczy uwzględnić 4 z 12 stacji: Letnicę, Stogi, Przeróbkę oraz jedną z pozostałych lokalizacji. Z kolei wykorzystując mech suchy, należy się skoncentrować na: Letnicy, Stogach, Brzeźnie oraz jednym z pozostałych punktów. Jeżeli w przyszłości zostanie podjęta decyzja kontynuowania biomonitoringu równoległego uwzględniającego oba typy biowskaźników, należy wybrać następujące stacje: Letnicę, Stogi, Przeróbkę oraz Brzeźno.

Warto zwrócić uwagę na fakt, że zastosowanie logiki rozmytej w badaniach biomonitoringowych nie tylko potwierdziło wyniki uzyskane metodami opartymi na zasadach logiki klasycznej, ale okazało się bardziej efektywne, zwłaszcza w przypadku analizy wyników uzyskanych dla mchu żywego. Oznacza to, że metody klasyczne i rozmyte prowadzą do podobnych wyników, jednak w badaniach środowiska logika rozmyta wydaje się bardziej właściwa/dopasowana, prawdopodobnie ze względu na „nieostry” charakter danych eksperymentalnych bazujących na naturalnych procesach, jak w przypadku wykorzystania żywych organizmów do określania stopnia zanieczyszczenia atmosfery.

## Literatura

1. Zechmeister H.G., Hohenwallner D., Riss A., Hanus-Iilnar A., Estimation of element deposition derived from road traffic sources by using mosses, *Environ. Pollut.*, **138**, 238–249, (2005).
2. Rühling L., Germund T., Changes in the atmospheric deposition of minor and rare elements between 1975 and 2000 in south Sweden as measured by moss analysis, *Environ. Pollut.*, **131**, 417–423, (2004).
3. Grünfeld K., Integrating spatio-temporal information in environmental monitoring data – a visualization approach applied to moss data, *Sci. Total. Environ.*, **347**, 1–20, (2005).
4. Poikolainen J., Kubin E., Piispanen J., Karhu J., Atmospheric heavy metal deposition in Finland during 1985–2000 using mosses as bioindicators, *Sci. Total. Environ.*, **318**, 171–185, (2004).



5. Couto J.A., Fernández J.A., Aboal J.R., Carballeira A., Active biomonitoring of element with terrestrial mosses: a comparison of bulk and dry deposition, *Sci. Total Environ.*, **324**, 211–222, (2004).
6. Coşkun M., Frontasyeva M.V., Steiness E., Cotuk A.Y., Pavlov S.S., Coşkun M., Sazonov A.S., Cayir A., Belivermis M., Atmospheric Deposition of Heavy Metals in Thrace Studies by analysis of moss (*Hypnum cupressiforme*), *Bull. Environ. Contam. Toxicol.*, **74**, 201–209, (2005).
7. Schintu M., Cogoni A., Durante L., Cantalupp C., Contu A., Moss (*Bryum radiculosum*) as a bioindicator of trace metal deposition around an industrialized area in Sardinia (Italy), *Chemosphere*, **60**, 610–618, (2005).
8. Dijngova R., Kovacheva P., Wagner G., Markert B., Distribution of platinum group elements and other traffic related elements among different plants along some highways in Germany, *Sci. Total. Environ.*, **308**, 235–246, (2003).
9. Raport o stanie środowiska województwa pomorskiego w 2002 roku, [Red.] A. Walkowiak, Inspekcja Ochrony Środowiska, WIOŚ, Gdańsk, Biblioteka Monitoringu Środowiska, Gdańsk 2003.
10. Wittig R., w: *Plants as Bioindicators. Indicators for Heavy Metals in the Terrestrial Environment*, [Red.] B. Markert, VCH, Weinheim, 1993, ch. 1, pp. 3.
11. Temsch E., w: *Sphagnum*, strona www: <http://www.botanik.univie.ac.at/pershome/temsch/basics.html>, wrzesień 2004.
12. Horne D., w: *Mosses and Liverworts.*, strona www: <http://www.naturegrid.org.uk/biodiversity/plants/crypmoss.html>, wrzesień 2004.
13. K. Gos, Wydział Biologiczny Uniwersytetu Gdańskiego, Konsultacje dotyczące biologii roślin.
14. Mazerski J., *Podstawy chemometrii*, Wydawnictwo Politechniki Gdańskiej, Gdańsk 2000.
15. Varmuza K., *Pattern Recognition in Chemistry*, Springer-Verlag, Berlin 1980.
16. Szczepaniak K., Astel A., Biziuk M., Bode P., Gos K., The attempt of atmospheric inorganic pollution assessment in the urban region of Gdańsk, northern Poland, *J. Radioanal. Nucl. Chem.*, w druku.
17. Massart D.L., Kaufman L., *The Interpretation of Analytical Chemistry Data by the Use of Cluster Analysis*, John Willey and Sons, New York 1983.
18. Rutkowska D., Piliński M., Rutkowski L., *Sieci neuronowe, algorytmy genetyczne i systemy rozmyte*, PWN, Warszawa 1999.
19. Zadeh L.A., *Fuzzy Sets*, *Inform. Control.* **8**, 338 (1965).
20. Astel A., Szczepaniak K., Namieśnik J., *Wielowymiarowe techniki analizy danych pomiarowych – przykłady z zakresu analityki i monitoringu środowiska*, *Ekologia i Technika XIII*, nr 3., 78 (2004).
21. Fuller M., *Introduction to Neuro-Fuzzy Systems*, *Advances in Soft Computing Series*, Springer-Verlag, Berlin/Heidelberg, 1999.



22. Sârbu C., Pop H.F., Fuzzy Soft-Computing Methods and Their Applications in Chemistry, w: [Red.] K.B. Lipkowitz, R. Larter, T.R. Cundari, Reviews in Computational Chemistry, Wiley-VCH, Weinheim 2004.
23. Pop H.F., Sârbu C., A New Fuzzy Regression Algorithm, Anal. Chem. **68**, 771 (1996).
24. Szczepaniak K., Sârbu C., Astel A., Raińska E., Biziuk M., Culicov O., Frontasyeva M.V., Bode P., Fuzzy logic application in assessment of phosphatic fertilizer plant's impact on the adjacent environment, CEJC **4**/1, 1 (2006).