



Instytut Badań Systemowych  
Polskiej Akademii Nauk

**mgr Piotr Kopka**

Autoreferat rozprawy doktorskiej

**Zastosowanie metodologii  
bayesowskiej w stochastycznej  
rekonstrukcji zdarzeń na  
przykładzie uwolnień  
niebezpiecznych gazów do  
atmosfery**

Promotor:  
dr hab. inż. Piotr Holnicki-Szulc

WARSZAWA 2015



# 1. Wstęp

Przechowywanie niebezpiecznych substancji oraz ich transport drogą kolejową, morską lub szlakami komunikacyjnymi powoduje potencjalne niebezpieczeństwo w przypadku awarii. Pomimo rozwoju technologii bezpieczeństwa oraz wprowadzaniu coraz bardziej restrykcyjnych przepisów, wielu awarii nie udało się uniknąć i wielu prawdopodobnie nie unikniemy w przyszłości. Zagrożenia związane z katastrofami przemysłowymi i ich skala wymuszają podejmowanie działań określających procedury postępowania, nie tylko na poziomie lokalnym, ale także na szczeblu międzynarodowym. Nie odnosi się to tylko do państw, w których do takowych doszło, ale do całego regionu, ponieważ administracyjne granice w żaden sposób nie chronią przed potencjalnymi skutkami. Jednym z poważniejszych zagrożeń związanym z awariami jest uwolnienie niebezpiecznych substancji (toksycznych, łatwopalnych, radioaktywnych), które mogą zagrażać zdrowiu ludzi znajdujących się w pobliżu. Nieoczekiwane wycieki materiałów szkodliwych mają również dalekosiężne skutki dla środowiska naturalnego.

Wybranymi przykładami tego typu incydentów są:

- Awaria elektrofiltrów kominowych huty żelaza w Algeciras w Hiszpanii (Estevan, 2003).
- Wypadek w elektrowni atomowej w Fukushima (Yasunari et al., 2011).
- Katastrofa w elektrowni atomowej w Czarnobylu (Kownacka, 2006).

W przypadku nieoczekiwanego uwolnienia substancji, oprócz standardowych procedur bezpieczeństwa, ważnym elementem jest przeciwdziałanie skutkom awarii. Działania prewencyjne uwzględniają przygotowanie procedury postępowania po zaistniałym wypadku. Kluczową kwestią we wczesnej fazie planowania jest identyfikacja źródła uwolnienia gazów. Informacje o potencjalnym miejscu pozwalają na dalsze działania oraz adekwatne zastosowanie procedur chroniących zdrowie i życie ludzi znajdujących się w obszarze narażenia. W przypadku nieoczekiwanego uwolnienia niebezpiecznych substancji rozprzestrzeniających się w powietrzu, sposobem aby poznać skalę niebezpieczeństwa jest symulacja transportu gazu z wykorzystaniem modelu dyspersyjnego. Komputerowe wspomaganie umożliwia szybką i bezpieczną identyfikację obszarów zagrożenia. Warunkiem koniecznym do uruchomienia tego typu symulacji jest poznanie charakterystyki źródła, jak i znajomość podstawowych parametrów meteorologicznych. Z punktu widzenia modelowania propagacji zanieczyszczeń, identyfikację parametrów źródła możemy rozważyć jako zadanie odwrotne. Szukanymi informacjami są parametry wejściowe

modelu, a dysponujemy częściową wiedzą o stężeniach, która zwykle pochodzi z sieci sensorów. Zakładamy, że znamy informacje o warunkach meteorologicznych, a przynajmniej podstawową wiedzę o lokalnym kierunku i sile wiatru. Ze względu na niepewność, która jest powiązana z danymi pomiarowymi oraz z modelem dyspersyjnym, rozpatrywany problem często nie ma jednoznacznego rozwiązania i musi być sformułowany w kategoriach probabilistycznych. W literaturze opisywane zagadnienie zostało określone mianem stochastycznej rekonstrukcji zdarzeń (ang. *Stochastic event reconstruction*), a szeroko pojęte podejście bayesowskie jako metoda rozwiązania tego problemu pojawia się w przeważającej liczbie publikacji.

## 1.1. Przegląd literatury

Jedną z pierwszych publikacji z dziedziny identyfikacji źródła uwolnienia substancji do atmosfery jest (Pudykiewicz, 1998), w której autorzy posłużyli się danymi z awarii w Algeciras. W pracach (Johannesson, Hanley, & Nitao, 2004) oraz (Johannesson et al., 2005) przedstawione są dynamiczne techniki Bayesa oraz algorytmy próbujące Markov Chain Monte Carlo (MCMC) dla problemu rekonstrukcji parametrów uwolnienia w oparciu o dane syntetyczne. W przypadku dyspersji gazów w środowiskach silnie zurbanizowanych, warto zwrócić uwagę na pozycje (Keats, Yee, & Lien, 2007) i (Chow, Kosovic, & Chan, 2008). W obu publikacjach zastosowano metodologię bayesowską na potrzeby testów wykorzystano dane eksperymentalne Joint Urban 2003, które zostały otrzymane w serii eksperymentów przeprowadzonych w Oklahoma City. Autorzy w (Keats et al., 2007) oraz (Chow et al., 2008) także użyli metod MCMC do próbkowania rozkładu a posteriori przestrzeni parametrów. W (Keats et al., 2007) jako testowego zbioru użyto danych z eksperymentu *Mock Urban Setting Trial* (MUST), natomiast w (Chow et al., 2008) zastosowano autorski syntetyczny przypadek z sześcianiem oddzielającym źródło od sensorów. Zasadniczą różnicą w podejściu autorów jest użycie innych funkcji wiarygodności oraz modeli dyspersji. W (Delle Monache et al., 2008) zastosowano algorytm MCMC dla danych pochodzących z awaryjnego uwolnienia materiałów radioaktywnych w Algeciras. Symulację dyspersji gazu przeprowadzono przy użyciu modelu *Lagrangian Operational Dispersion Integrator* (LODI) (Leone Jr et al., 2005). Natomiast w publikacji (Senocak, Hengartner, Short, & Daniel, 2008) zaproponowano wariant funkcji wiarygodności, w którym wzięto pod uwagę zarówno zerowe i niezerowe pomiary stężeń z sieci czujników. Procedurę rekonstrukcji oparto na metodach MCMC, a jako model dyspersji zastosowano modele smugowe Gaussa (Arya, 1999), co pozwoliło na estymację sześciu składowych opisujących źródło uwolnienia. Na koniec, warto zwrócić uwagę na pracę (Wade & Senocak, 2013), w której zaproponowano metodologię rekonstrukcji wielu źródeł emisji.

## 1.2. Cel pracy

Celem tej rozprawy doktorskiej jest opracowanie algorytmów oraz zaproponowanie systemu pozwalającego na identyfikację parametrów źródeł uwolnienia gazów do atmosfery na podstawie stężeń uwolnionej substancji pochodzących z sieci sensorów.

## 1.3. Postawiony problem badawczy

- Analiza dotychczas opublikowanych i dostępnych algorytmów oraz systemów zastosowanych w problemie stochastycznej rekonstrukcji zdarzeń.
- Zbudowanie własnego systemu opierającego się na metodach bayesowskich oraz mechanizmie rozproszonych modeli dyspersji.
- Wykorzystanie zaawansowanych algorytmów oraz metod, takich jak sekwencyjne metody Monte Carlo (ang. Sequential Monte Carlo) oraz przybliżone obliczenia bayesowskie (ang. Approximate Bayesian Computation).
- Opracowanie własnych modyfikacji do algorytmów dedykowanych stochastycznej rekonstrukcji zdarzeń.
- Zastosowanie modeli dyspersji, które nie są obecne w publikacjach poświęconych rekonstrukcji, takich jak SCIPUFF (Second-order Closure Integrated Puff) (Sykes, Parker, Henn, Cerasoli, & Santos, 2000), QUIC (Quick Urban and Industrial Complex Dispersion Modeling System) (Williams, Brown, Singh, & Boswell, 2004).
- Analiza wielu wariantów uwolnienia gazów do atmosfery, opierających się na nierekonstruowanych dotychczas eksperymentach i problemach:
  - rekonstrukcja parametrów źródła dla eksperymentu uwolnienia gazu  $SF_6$  w okolicach elektrowni atomowej KORI w Korei Południowej (Han, Kim, Suh, Hwang, & Choi, 2001),
  - problem identyfikacji charakterystyki źródła poruszającego się w czasie na podstawie danych z eksperymentu OLAD (Over-land atmospheric dispersion) (Biltoft, 2000),
  - lokalizacja źródła uwolnienia w środowisku silnie zurbanizowanym na przykładzie danych pochodzących z serii eksperymentów DAPPLE (Urban tracer dispersion experiment in London) (Arnold et al., 2004).

## 1.4. Struktura autoreferatu

W następnym rozdziale przedstawiony został model wnioskowania bayesowskiego przystosowany do problemu stochastycznej rekonstrukcji zdarzeń. Aby podkreślić praktyczny aspekt rozprawy, część eksperymentalna w dużej mierze jest skoncentrowana na rekonstrukcji parametrów źródeł dla danych pochodzących z

fizycznych eksperymentów przeprowadzanych na całym świecie. Rozdział 3 jest przeglądem analizowanych przypadków wraz z krótkim omówieniem dotychczasowych wyników oraz odniesieniami do już opublikowanych prac.

## 2. Metodologia bayesowska

Twierdzenia Bayesa dostosowane do problemu stochastycznej rekonstrukcji zdarzeń występuje w wielu publikacjach (Keats et al., 2007), (Chow et al., 2008) w następującej formie:

$$P(M|D,I) = \frac{P(M|I)P(D|M,I)}{P(D|I)} \propto P(M|I)P(D|M,I) \quad (2.1)$$

gdzie  $M$  reprezentuje konfigurację modelu, natomiast  $D$  jest zbiorem obserwowanych danych. Element  $I$  odnosi się do wszystkich dodatkowych informacji, które mogą być użyte w modelu. Warto wspomnieć, że rozważane elementy należy rozumieć w ogólnym sensie, jednak na potrzeby opisywanego problemu przyjmijmy następujące założenia:

- model  $M$  będzie przestrzenią wartości parametrów źródła dla możliwych konfiguracji modelu dyspersji, takich jak np. pozycja źródła, ilość emitowanej substancji,
- dane  $D$  będą interpretowane jako pomiary stężeń, które pochodzą z sieci sensorów,
- informacja  $I$  odnosi się do danych zewnętrznych, które mogą być użyte w modelu (kierunek wiatru, temperatura, itd.).

W formule (2.1) możemy wyróżnić następujące składowe:

**Rozkład a priori**  $P(M|I)$  - wyraża stan wiedzy na temat modelu przed uwzględnieniem danych  $D$ . Jeśli jesteśmy nieświadomi początkowych wartości parametrów modelu, wybór dystrybucji a priori powinien odzwierciedlać ten stan niewiedzy.

**Funkcja wiarygodności**  $P(D|M,I)$  określa powiązanie między danymi  $D$  a modelem  $M$ . Dla rozważnego modelu, wiarygodność bayesowska nie jest stricte rozkładem prawdopodobieństwa ze względu na to, że dane  $D$  zostały fizycznie zaobserwowane (ustalone).

**Rozkład a posteriori**  $P(M|D,I)$  jest rozwiązaniem problemu wnioskowania i wyraża prawdopodobieństwo modelu  $M$  po wzięciu pod uwagę danych  $D$ .

W formule (2.1) występuje również wiarygodność globalna  $P(D,I)$  nazywana „ewidencją”, która pełni rolę czynnika normalizującego.

## 2.1. Testowane metody

Celem procedury rekonstrukcji źródła uwolnienia jest wyznaczenie rozkładu a posteriori parametrów źródła, po uwzględnieniu danych napływających z sieci sensorów. Aby tego dokonać należy przeprowadzić próbkowanie przestrzeni parametrów. W publikacjach (Borysiewicz, Wawrzynczak, & Kopka, 2012b) oraz (Borysiewicz, Wawrzynczak, & Kopka, 2012a) zostały zastosowane metody MCMC do problemu rekonstrukcji parametrów źródła dla syntetycznych danych. Wartości stężeń gazu w sensorach zostały wygenerowane za pomocą modelu Gaussa (Arya, 1999) z pewnym zaburzeniem. Rekonstrukcja źródła dotyczyła znalezienia 5 parametrów opisujących źródło ( $(x,y)$  - pozycja źródła,  $q$  - poziom emisji,  $\zeta_1, \zeta_2$  - składowe parametryzujące kształt obłoku). Zastosowanym modelem dyspersyjnym był model Gaussa. W ramach publikacji (Borysiewicz et al., 2012b) zostały przetestowane warianty rozszerzające metodę MCMC.

W dalszych publikacjach skoncentrowano się na sekwencyjnych metodach Monte Carlo (ang. Sequential Monte Carlo - SMC). SMC to ogólna nazwa dla algorytmów, które służą do rozwiązywania problemów dynamicznych metodami Monte Carlo, gdzie rozkłady a posteriori są zależne od czasu. Wyniki zastosowania metod SMC dla danych syntetycznych zostały pokazane w publikacjach (Wawrzynczak, Kopka, & Borysiewicz, 2014) oraz (Kopka, Wawrzynczak, & Borysiewicz, 2013).

Zastosowanie metod z klasy przybliżonych obliczeń bayesowskich (ang. Approximate Bayesian computation - ABC) wyraźnie wpłynęło na jakość otrzymanych wyników. W publikacji (Bonassi, West, et al., 2015) został zaprezentowany sekwencyjny algorytm ABC, pozwalający na łatwiejszy dobór funkcji wiarygodności, która została zastąpiona miarą odległości między danymi pochodzącymi z symulacji a pomiarami z sensorów. Sekwencyjna metoda ABC okazała się skuteczna i została zastosowana przy analizie problemów, w których dane pochodziły z eksperymentów rzeczywistych. Wyniki obliczeń uzyskanych metodą ABC zostały częściowo przedstawione w następnym rozdziale.



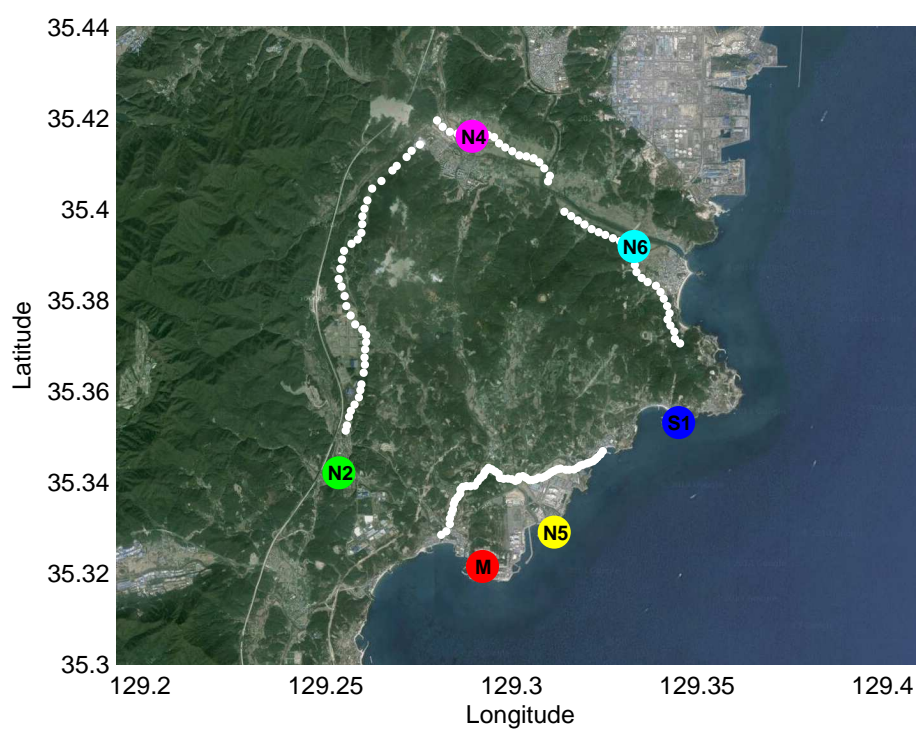
## 3. Eksperymenty badawcze

Poniżej opisano stochastyczną rekonstrukcję fizycznych eksperymentów, w których przeprowadzono kontrolowane uwolnienia gazów w różnych środowiskach.

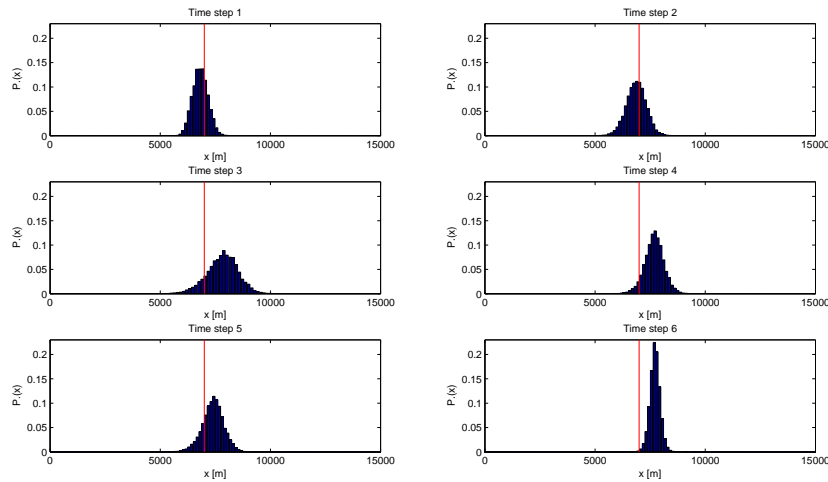
### 3.1. Eksperyment uwolnienia gazu $SF_6$ w elektrowni atomowej w KORI

W latach 2000-2002 przeprowadzono sześć terenowych eksperymentów dyspersyjnych w najbliższej okolicy elektrowni atomowej Kori położonej w wschodniej części Korei Południowej. W raporcie (Han et al., 2001) wyróżniono dwa podstawowe cele doświadczeń: analiza potencjalnych zagrożeń wynikających z sąsiedztwa elektrowni jądrowej oraz walidacja systemu czasu rzeczywistego *FADAS* (Following Dose Assessment System). Analizowane wyniki pochodziły z trzeciego eksperymentu, który odbył się 31 maja 2001 roku. Znacznikiem był gaz  $SF_6$  (sulfur hexafluoride) uwolniony w ilości 75.79kg/h między godzinami 12.30-16.00. Pomiaru, udostępnione przez autorów, zostały podane w interwałach 10 minutowych, w okresie czasu między godziną 15.00 a 16.00 tego samego dnia. Aż 140 urządzeń pomiarowych rozlokowanych w 2 liniach oddalonych od punktu uwolnienia średnio o 3km i 12 km (białe punkty na rys. 3.1). Pomiaru wiatru pochodziły z 5 stacji pomiarowych (kolorowe, ponumerowane punkty rys. 3.1).

Celem publikacji (Kopka, Wawrzynczak, & Borysiewicz, 2015b) było określenie rozkładów prawdopodobieństwa a posteriori dla trzech parametrów: pozycji źródła  $(x,y)$  oraz poziomu emisji  $(q)$ . Do procedury rekonstrukcji użyto metody hybrydowej łączącej MCMC, w kroku inicjalizującym oraz SMC w dalszych krokach czasowych. Otrzymane brzegowe rozkłady a posteriori dla trzech parametrów pokazane na wykresach 3.2, 3.3 oraz 3.4. Dla parametrów pozycji źródła uzyskane prawdopodobieństwo w większości kroków czasowych pokrywa się z szukaną wartością  $x$  oraz  $y$ . W ostatnim kroku czasowym następuje przesunięcie przewidywanej pozycji źródła w prawo, natomiast dla rozkładu a posteriori parametru  $y$  oczekiwana wartość tego parametru praktycznie pokrywa się z największym prawdopodobieństwem. Parametr  $q$  jest błędnie estymowany we wszystkich krokach czasowych. Prawdopodobnym powodem nieprawidłowości w oszacowaniu wartości poziomu uwolnienia jest zerowa wartość stężenia na wielu sensorach spowodowana przez ukształtowanie terenu (Han et al., 2001). W modelu dyspersyjnym SCIPUFF,



Rysunek 3.1. Mapa prezentująca obszar eksperymentu KOR1. Czerwony punkt M – lokalizacja źródła; białe punkty – linie sensorów; pozostałe punkty (N2,N4,N5,N6,S1) pokazują miejsca lokacji 5 meteorologicznych stacji pomiarowych.

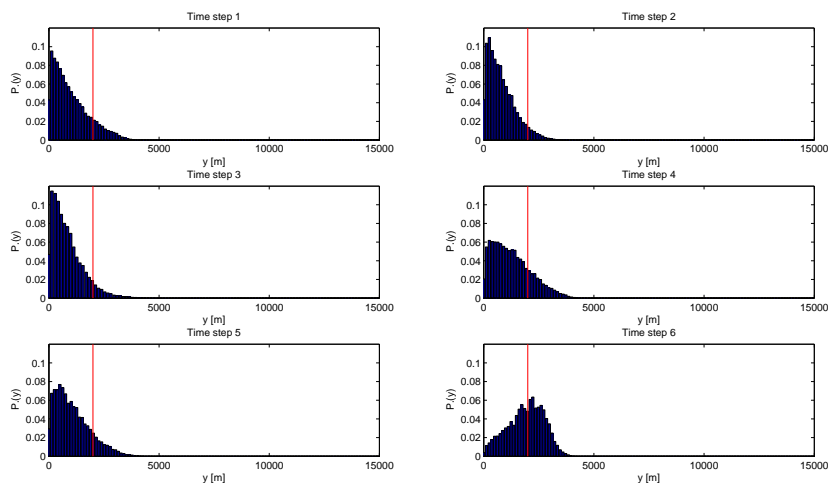


Rysunek 3.2. Rozkład a posteriori parametru  $x$  otrzymany z wygenerowanych próbek. Czerwona pionowa linia określa szukaną wartość parametru. Dane pochodzą z 6 kroków czasowych. Wyniki pochodzą z rekonstrukcji eksperymentu KORI.

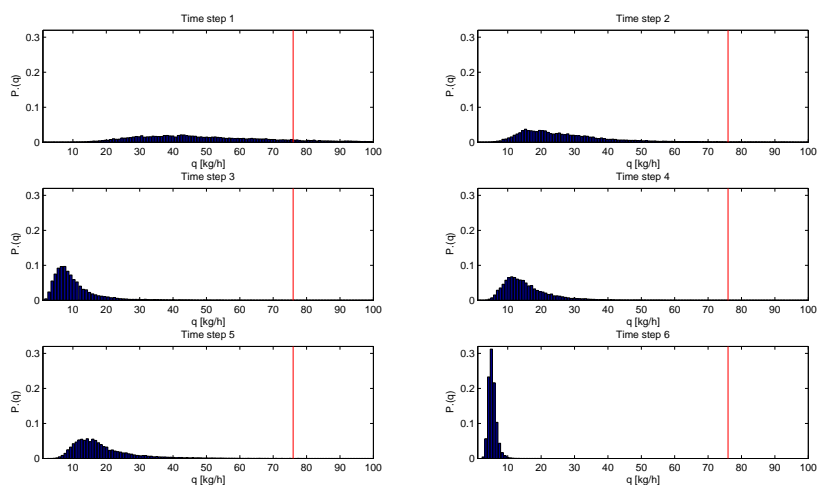
który został użyty w procedurze rekonstrukcji eksperymentu Kori, ukształtowanie terenu jest uwzględniana tylko jako współczynnik szorstkości, co okazało się niewystarczające. W dalszych pracach badawczych planowane jest powtórzenie eksperymentów z zastosowaniem modelu w większym stopniu uwzględniającego wpływ ukształtowania terenu.

### 3.2. Eksperyment z poruszającym się źródłem OLAD

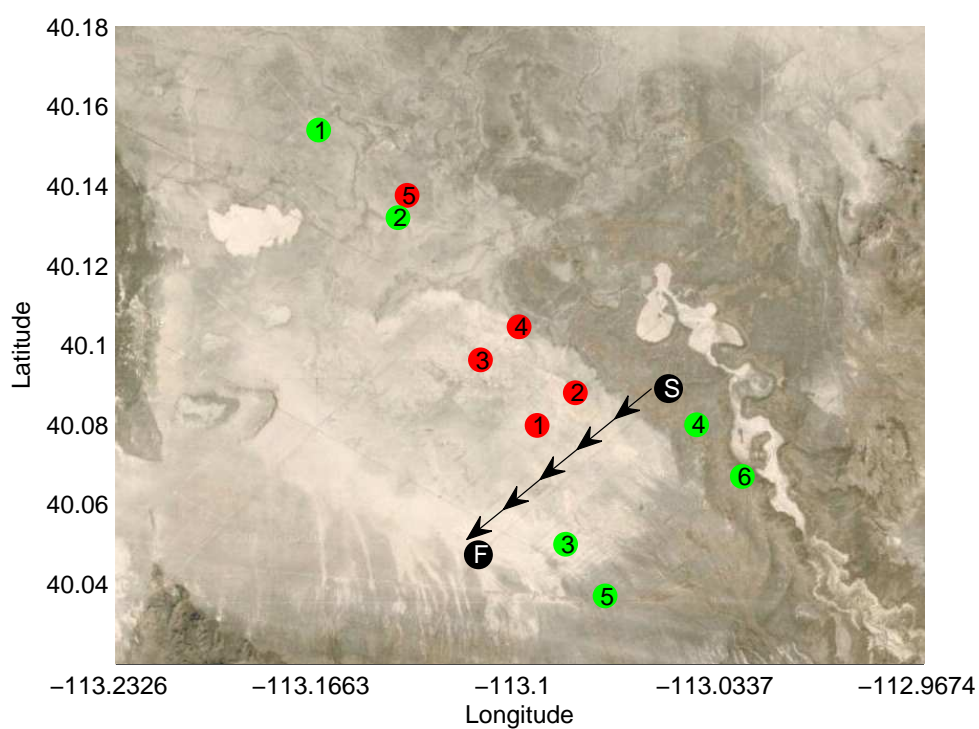
Eksperyment Over-Land Alongwind Dispersion (OLAD) został przeprowadzony między 8-25 września 1997 roku na terenie poligonu armii USA. Bezpośrednim celem badań było uzyskanie informacji o trajektorii pasywnej, przemieszczającej się chmury gazu na obszarze 20 km. Pozyskane dane miały posłużyć do oceny różnych modeli dyspersji. Test OLAD zaprojektowano na zasadzie ciągłego uwalniania uprzednio ustalonej ilości gazu SF6 wzdłuż drogi prostopadłej do kierunku wiatru. Urządzenie emitujące ulokowane na wojskowym pojeździe uwalniało 1.5kg substancji na minutę, w trakcie pokonywania dystansu 10 kilometrów. Na terenie poligonu umieszczono trzy linie sensorów oraz przenośne stacje meteorologiczne mierzące podstawowe informacje pogodowe, takie jak: kierunek i siłę wiatru, temperaturę oraz wilgotność. Rozmieszczenie wszystkich komponentów eksperymentu zostało pokazane na rysunku 3.5. Rekonstrukcja opierająca się na danych z eksperymentu OLAD obejmowała analizę 7 parametrów charakteryzujących źródło uwolnienia:  $(x,y)$  - punkt startowy pojazdu;  $d$  - kierunek poruszania się;  $s$  - prędkość pojazdu,  $q$



Rysunek 3.3. Rozkład a posteriori parametru  $y$  otrzymany z wygenerowanych próbek. Czerwona pionowa linia określa szukaną wartość parametru. Dane pochodzą z 6 kroków czasowych. Wyniki pochodzą z rekonstrukcji eksperymentu KORI.



Rysunek 3.4. Rozkład a posteriori parametru  $q$  otrzymany z wygenerowanych próbek. Czerwona pionowa linia określa szukaną wartość parametru. Dane pochodzą z 6 kroków czasowych. Wyniki pochodzą z rekonstrukcji eksperymentu KORI.



Rysunek 3.5. Mapa prezentująca obszar eksperymentu OLAD. Czarny punkt (S) – startowa lokalizacja źródła; czarny punkt (F) – końcowa lokalizacja źródła; strzałki – kierunek ruchu pojazdu; czerwone punkty – sensory; zielone punkty – przenośne meteorologiczne stacje pomiarowe.

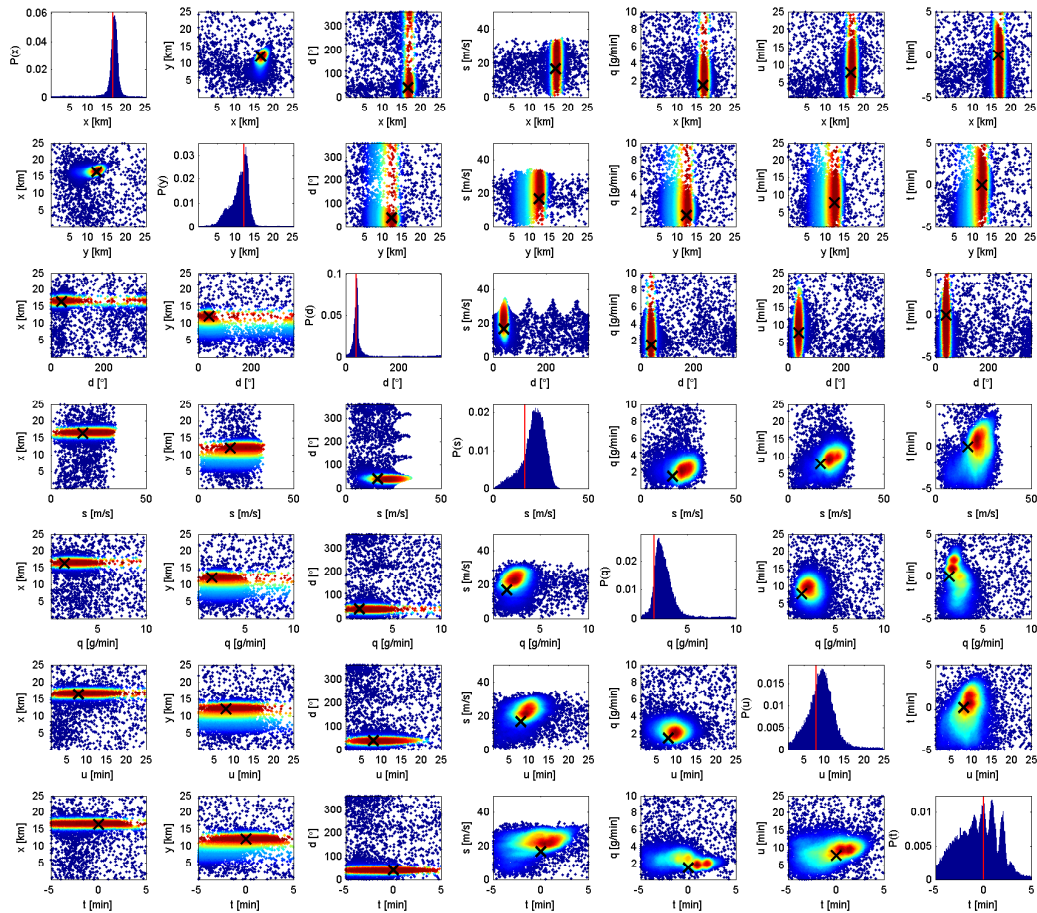
- poziom emisji;  $u$  - całkowity czas uwolnienia gazu;  $t$  - czas rozpoczęcia uwolnienia. Jako model dyspersyjny wykorzystano SCIPUFF w trybie źródła poruszającego się ruchem jednostajnym w określonym kierunku. W symulacji wykorzystano dane ze stacji metrologicznych (rysunku 3.5 - zielone punkty). Eksperyment trwał 45 minut, a procedura rekonstrukcji rozpoczęła się po 10 minutach od rozpoczęcia przejazdu. Dane pomiarowe pochodzące z sensorów były aktualizowane co 60 sekund, co dało 35 symulacyjnych kroków czasowych. W analizie eksperymentu OLAD zastosowano metodę ABC.

Na wykresie 3.6 pokazano brzegowe rozkłady a posteriori wszystkich parametrów oraz ich kombinacji. Na przekątnej pionowa czerwona linia oznacza szukane wartości parametrów, a na pozostałych rysunkach obszary charakteryzujące się wyraźniejszą czerwienią określają większą koncentrację próbek, co w konsekwencji prowadzi do wyższych wartości prawdopodobieństwa w danych miejscach. Możemy zauważyć, że dla większości charakterystyk źródła wysokie prawdopodobieństwo pokrywa się z rzeczywistymi wartościami opisującymi eksperyment OLAD. Publikacja na podstawie opisanego eksperymentu oraz zaprezentowanych wyników jest w trakcie redagowania, natomiast część wyników została przedstawiona w (Kopka, Wawrzynczak, & Borysiewicz, 2015a).

### 3.3. Eksperyment miejski DAPPLE

DAPPLE to ogólna nazwa dla kampanii meteorologicznych i dyspersyjnych eksperymentów miejskich przeprowadzonych przez konsorcjum brytyjskich uniwersytetów. Pierwszy z nich trwał od 2002 do 2006 roku i był finansowany przez brytyjski program EPSRC, natomiast drugi był odbył się w ramach programu CBRN w latach 2006-2010. Wszystkie testy zostały przeprowadzone w okolicach skrzyżowania Marylebone Road i Gloucester Place w centrum Londynu. Interesującym, z punktu widzenia rekonstrukcji, było badanie, które odbyło się w 28 czerwca 2007 roku. Mapę eksperymentu przedstawiono na rysunku 3.7 (miejsce uwolnienia – zielony punkt X; pozycje 18 receptorów- żółte punkty). W przeciwieństwie do poprzednich eksperymentów gazem uwolnionym podczas eksperymentu DAPPLE był perfluorometyl-cyclohexane (PMCH;C7F14) w ilości 323mg dla opisywanego przypadku. Dane dotyczące pogody pochodziły z dachu budynku rady miejskiej (18m) na rysunku 3.7 – czerwona gwiazdka. Okres symulacji to łączenie 30 minut podzielone na 3 minutowe odstępy czasowe definiujące kroki w stochastycznej symulacji metodą ABC. W analizie numerycznej wykorzystano model QUIC-PLUM do predykcji koncentracji substancji oraz modelu QUIC-URB do określenia pola wiatru między budynkami.

Wyniki z rekonstrukcji trzech parametrów uwolnienia: pozycji źródła ( $x,y$ )



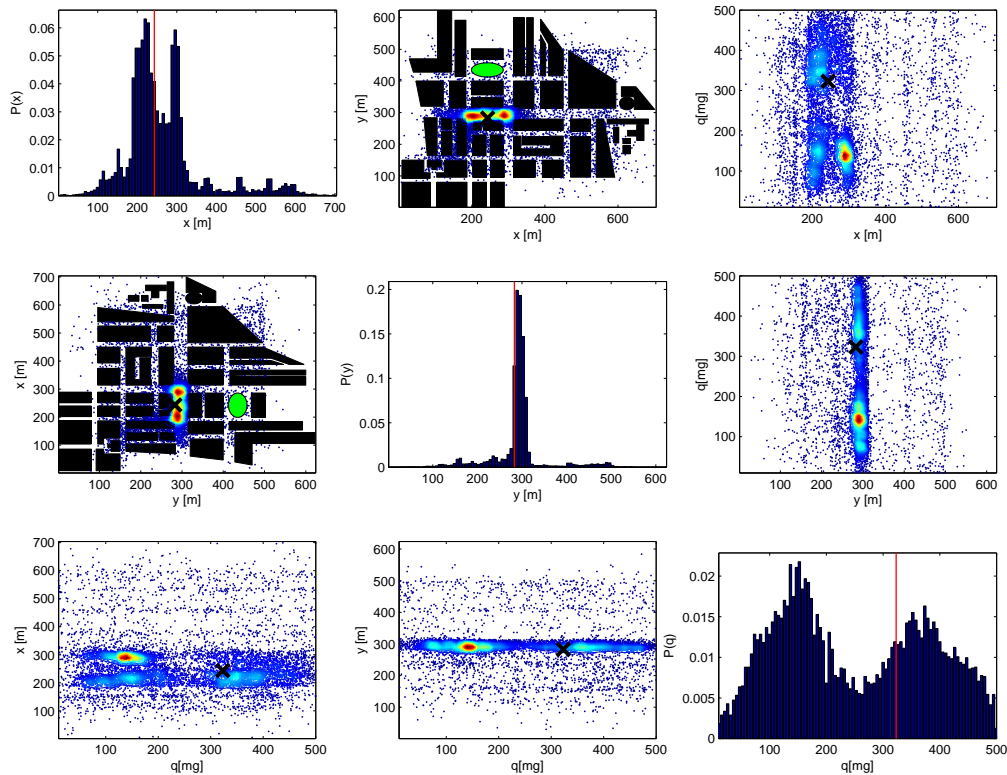
Rysunek 3.6. Na przekątnej - brzegowe rozkład a posteriori dla wszystkich parametrów. Czerwone linie określa szukane wartości parametrów. Pozostałe wykres - rozkłady dla kombinacji dwóch parametrów. Czarny krzyż oznacza szukaną wartość. Wyniki otrzymane po 35 krokach czasowym. Dla parametru  $d$  - kierunek wschód-zachód odpowiada za  $0^\circ$  a orientacja jest przeciwna do kierunku wskazówek zegara; dla parametru  $t$  - wartość 0 oznacza rzeczywisty moment rozpoczęcia uwolnienia. Wyniki pochodzą z rekonstrukcji eksperymentu OLAD.





Rysunek 3.7. Mapa prezentująca obszar eksperymentu DAPPLE. Zielony punkt X – lokalizacja źródła; żółte punkty – lokalizacja 18 sensorów; czerwona gwiazdka – stacja meteorologiczna na dachu budynku rady miejskiej.





Rysunek 3.8. Na przekątnej - brzegowe rozkład a posteriori dla parametrów  $(x,y,q)$ . Czerwone linie określa szukane wartości parametrów. Pozostałe wykres - koncentrację próbek dla kombinacji parametrów. Czarny krzyż oznacza szukaną wartość. Wyniki pochodzą z rekonstrukcji eksperymentu DAPPLE.

oraz poziomu emisji  $q$  przedstawione są na rysunku 3.8. Możemy zaobserwować, że próbki koncentrują się w pobliżu właściwej lokalizacji źródła, co ma konsekwencję we wzroście wartości prawdopodobieństwa w brzegowych rozkładach a posteriori parametrów. Wyniki rekonstrukcji eksperymentu DAPPLE zostały przedstawione na konferencji **Information technologies: research and their interdisciplinary application** oraz opisanie w publikacji, która jest obecnie recenzowana.



## 4. Podsumowanie

### 4.1. Podsumowanie

W pracy przedstawiono zagadnienie stochastycznej rekonstrukcji zdarzeń dla problemu identyfikacji źródeł uwolnienia gazów do atmosfery na podstawie stężeń uwolnionej substancji pochodzących z sieci sensorów. W tym celu opracowano odpowiednie algorytmy, przeprowadzono badania na danych syntetycznych oraz rzeczywistych eksperymentach, które potwierdziły działanie opisywanych metod. Zaawansowana rozprawy wynosi obecnie około 70%. Do zrealizowania pozostały badania większej ilości parametrów dla już opracowanych eksperymentów oraz szerszy opis zastosowanych algorytmów i ich modyfikacji.



## Bibliografia

- Arnold, S., ApSimon, H., Barlow, J., Belcher, S., Bell, M., Boddy, J., . . . others (2004). Introduction to the DAPPLE air pollution project. *Science of the Total Environment*, 332(1), 139–153.
- Arya, S. P. (1999). Air pollution meteorology and dispersion. , 253–270.
- Biltoft, T. S., C. A. (2000). Final test report of the Over-Land Alongwind Dispersion Field Trials.
- Bonassi, F. V., West, M., et al. (2015). Sequential Monte Carlo with Adaptive Weights for Approximate Bayesian Computation. *Bayesian Analysis*, 10(1), 171–187.
- Borysiewicz, M., Wawrzynczak, A., & Kopka, P. (2012a). Bayesian-based methods for the estimation of the unknown model’s parameters in the case of the localization of the atmospheric contamination source. *Foundations of Computing and Decision Sciences*, 37(4), 253–270.
- Borysiewicz, M., Wawrzynczak, A., & Kopka, P. (2012b). Stochastic algorithm for estimation of the model’s unknown parameters via Bayesian inference. In *Computer science and information systems (fedcsis), 2012 federated conference on* (pp. 501–508).
- Chow, F. K., Kosovic, B., & Chan, S. (2008). Source inversion for contaminant plume dispersion in urban environments using building-resolving simulations. *Journal of applied meteorology and climatology*, 47(6), 1553–1572.
- Delle Monache, L., Lundquist, J. K., Kosovic, B., Johannesson, G., Dyer, K. M., Aines, R. D., . . . others (2008). Bayesian inference and Markov chain Monte Carlo sampling to reconstruct a contaminant source on a continental scale. *Journal of Applied Meteorology and Climatology*, 47(10), 2600–2613.
- Estevan, M. (2003). Consequences of the Algeciras accident, and the Spanish system for the radiological surveillance and control of scrap and the products of its processing. *Security of Radioactive Sources*, 357.
- Han, M., Kim, E., Suh, K., Hwang, W., & Choi, Y. (2001). Field tracer experiments over nuclear sites for the validation of a Korean real-time atmospheric dispersion and dose assessment system (FADAS). *International journal of environment and pollution*, 16(1-6), 227–236.
- Johannesson, G., Dyer, K., Hanley, W., Kosovic, B., Larsen, S., Loosmore, G., . . . Mirin, A. (2005). Sequential Monte-Carlo based framework for dynamic data-driven event reconstruction for atmospheric release. In *Proc. of the*

- joint statistical meeting, minneapolis, mn, american statistical association and cosponsors* (pp. 73–80).
- Johannesson, G., Hanley, B., & Nitao, J. (2004). Dynamic Bayesian models via Monte Carlo an introduction with examples. *Lawrence Livermore National Laboratory, UCRL-TR-207173*.
- Keats, A., Yee, E., & Lien, F.-S. (2007). Bayesian inference for source determination with applications to a complex urban environment. *Atmospheric environment*, 41(3), 465–479.
- Kopka, P., Wawrzynczak, A., & Borysiewicz, M. (2013). Time dependent global optimization via Bayesian inference and Sequential Monte Carlo sampling. In *Computer science and information systems (fedcsis), 2013 federated conference on* (pp. 363–370).
- Kopka, P., Wawrzynczak, A., & Borysiewicz, M. (2015a). The Approximate Bayesian Computation methods in the localization of the atmospheric contamination source. In *Journal of physics: Conference series* (Vol. 633, p. 012118).
- Kopka, P., Wawrzynczak, A., & Borysiewicz, M. (2015b). Localizing of the atmospheric contamination source based on the Kori field tracer experiment data. *Operations Research and Decisions*, 2, 35–50.
- Kownacka, L. (2006). Environmental air transport and vertical distribution of radioactive substances over territory of Poland after the Chernobyl npp accident.
- Leone Jr, J. M., Nasstrom, J. S., Maddix, D. M., Larson, D. J., Sugiyama, G., & Ermak, D. L. (2005). *Lagrangian Operational Dispersion Integrator (lodi) user's guide* (Tech. Rep.). Report UCRL-AM-212798, Lawrence Livermore National Laboratory, Livermore, CA.
- Pudykiewicz, J. A. (1998). Application of adjoint tracer transport equations for evaluating source parameters. *Atmospheric environment*, 32(17), 3039–3050.
- Senocak, I., Hengartner, N. W., Short, M. B., & Daniel, W. B. (2008). Stochastic event reconstruction of atmospheric contaminant dispersion using Bayesian inference. *Atmospheric Environment*, 42(33), 7718–7727.
- Sykes, R. I., Parker, S., Henn, D., Cerasoli, C., & Santos, L. (2000). PC-SCIPUFF Version 1.3 technical documentation. *Titan Corporation, ARAP Report No, 725*.
- Wade, D., & Senocak, I. (2013). Stochastic reconstruction of multiple source atmospheric contaminant dispersion events. *Atmospheric Environment*, 74, 45–51.
- Wawrzynczak, A., Kopka, P., & Borysiewicz, M. (2014). Sequential Monte Carlo in Bayesian assessment of contaminant source localization based on the sensors concentration measurements. In *Parallel processing and applied mathematics* (pp. 407–417). Springer.
- Williams, M. D., Brown, M. J., Singh, B., & Boswell, D. (2004). Quic-plume

theory guide. *Los Alamos National Laboratory*.

Yasunari, T. J., Stohl, A., Hayano, R. S., Burkhart, J. F., Eckhardt, S., & Yasunari, T. (2011). Cesium-137 deposition and contamination of Japanese soils due to the fukushima nuclear accident. *Proceedings of the National Academy of Sciences*, *108*(49), 19530–19534.