

63/2010

18

Raport Badawczy
Research Report

RB/6/2010

**Niepewność w systemach
zarządzania jakością
powietrza atmosferycznego**

P. Holnicki

Instytut Badań Systemowych
Polska Akademia Nauk

Systems Research Institute
Polish Academy of Sciences



POLSKA AKADEMIA NAUK

Instytut Badań Systemowych

ul. Newelska 6

01-447 Warszawa

tel.: (+48) (22) 3810100

fax: (+48) (22) 3810105

Kierownik Pracowni zgłaszający pracę:
Prof. dr hab. inż. Zbigniew Nahorski

Warszawa 2010

NIEPEWNOŚĆ W SYSTEMACH ZARZĄDZANIA JAKOŚCIĄ POWIETRZA ATMOSFERYCZNEGO

Spis treści:

1. Wstęp	3
2. Opis matematyczny procesów transportu zanieczyszczeń	6
3. Wpływ danych wejściowych na jakość prognoz	7
3.1. Niepewność elementów prognozy meteorologicznej	7
3.2. Dane meteorologiczne a parametry równań transportu	8
3.3. Dane emisyjne	10
4. Niepewność w prognozowaniu rozkładów stężeń	11
4.1. Wyniki obliczeń testowych	11
4.1. Podsumowanie	20
5. Analiza niepewności w rozwiązaniach zadań decyzyjnych	21
5.1. Sformułowanie zadania - wybór strategii ograniczenia emisji	21
5.2. Analiza niepewności - wyniki obliczeń	23
6. Wnioski	33
Literatura	35
Abstract	36

NIEPEWNOŚĆ W SYSTEMACH ZARZĄDZANIA JAKOŚCIĄ POWIETRZA ATMOSFERYCZNEGO

Piotr Holnicki

*Instytut Badań Systemowych PAN, Warszawa
holnicki@ibspan.waw.pl*

Wspomaganie decyzji i zarządzanie jakością powietrza atmosferycznego wymaga powiązania różnych kategorii danych wejściowych (dane emisyjne, meteorologiczne, fizjograficzne parametry obszaru) oraz analitycznego opisu procesów rozprzestrzeniania się zanieczyszczeń (transport, dyspersja, depozycja, przemiany fizyko-chemiczne). Zadaniem właściwego modelu jest dostarczenie ilościowej oceny intensywności poszczególnych procesów oraz ich wyników w postaci rozkładu stężenia zanieczyszczeń lub ich depozycji. Dane te są z kolei podstawą do oceny wynikających stąd zagrożeń dla środowiska naturalnego oraz wspomaganie decyzji planistycznych. Duża złożoność systemu powoduje, że w jego prognozach istnieje dość szeroki zakres niepewności, który należy uwzględnić w podejmowanych decyzjach. Uważa się, że głównymi źródłami niepewności takich prognoz są wejściowe dane emisyjne i meteorologiczne. Celem pracy jest określenie wpływu niepewności i nieprecyzyjności tych dwóch podstawowych grup danych na niepewność prognoz generowanych przez model, a ostatecznie – na decyzje dotyczące zarządzania jakością powietrza. Obliczenia testowe przeprowadzono na danych rzeczywistych dotyczących wybranego regionu przemysłowego, przy czym regionalny model REGFOR3 [5] wykorzystano do powiązania emisji źródeł z rozkładem średniorocznego stężenia dwutlenku siarki w obszarze.

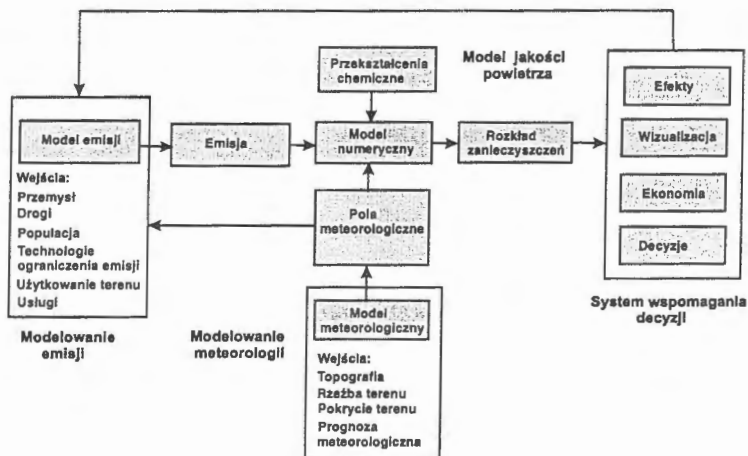
Słowa kluczowe: model propagacji zanieczyszczeń, zintegrowany system wspomaganie decyzji, analiza niepewności prognoz.

1. Wstęp

Systemy oceny jakości powietrza atmosferycznego należą do najbardziej złożonych struktur, w których wykorzystywane są komputerowe modele rozprzestrzeniania się zanieczyszczeń [5,7,10,12]. Ich budowa i zasada działania łączy wiedzę z różnych dziedzin nauki, takich jak: fizyka (np. modele transportu zanieczyszczeń w atmosferze), chemia (np. reakcje chemiczne między składnikami zanieczyszczeń), nauki ekonomiczne (np. analiza kosztów ograniczania emisji, wybór „czystych” technologii), ochrona zdrowia (np. wpływ zanieczyszczeń na zdrowie i długość życia), biologia (np. wpływ zanieczyszczeń na środowisko przyrodnicze), czy informatyka (implementacja komputerowa). Opis matematyczny procesów rozprzestrzeniania się zanieczyszczeń jest najczęściej oparty na odpowiednim układzie równań adwekcji-dyfuzji (lub równań transportu), opisujących ich transport w polu wiatru, mieszanie turbulencyjne, przemiany fizyko-chemiczne, opadanie na podłoże (procesy tzw. „suchej” i „mokrej” depozycji). Modele te są obecnie wykorzystywane do wspomaganie decyzji na różnych szczeblach w dziedzinie kontroli i zarządzania jakością środowiska [1,2,12,13].

Zarządzanie jakością powietrza atmosferycznego wymaga powiązania różnych kategorii danych wejściowych (dane emisyjne, meteorologiczne, fizjograficzne parametry obszaru) oraz analitycznego opisu procesów rozprzestrzeniania się zanieczyszczeń (transport, dyspersja, depozycja, przemiany fizyko-chemiczne). Zadaniem właściwego modelu jest dostarczenie ilościowej oceny intensywności poszczególnych procesów oraz ich wyników w postaci rozkładu stężenia zanieczyszczeń lub ich depozycji. Dane te są podstawą do oceny wynikających stąd zagrożeń dla środowiska naturalnego [1,5,7,12,15] (w tym dla zdrowia ludzkiego) oraz do wyboru właściwej (optymalnej) strategii przeciwdziałania, np. przez ograniczenie poziomu emisji lub przejście na inną technologię wytwarzania energii.

Złożoność modeli opisujących procesy zachodzące w systemach środowiskowych, a zwłaszcza systemów wspomagania decyzji opartych na tych modelach (porównaj ogólny schemat blokowy przedstawiony na rys. 1) jest bardzo duża. Dlatego też w generowanych przez ten system prognozach i podejmowanych na tej podstawie decyzjach istnieje dość duży zakres niepewności, który powinien być brany pod uwagę. Źródła tej niepewności leżą zarówno w samym modelu (uproszczenia opisu matematycznego, pomijanie lub parametryzacja pewnych procesów), jego implementacji numerycznej (aproxymacja skończenie-wymiarowa procesów ciągłych, dyskretyzacja czasowo-przestrzenna obszaru, opis procesów chemicznych, opis dyfuzji turbulencyjnej) oraz przede wszystkim w danych wejściowych, na których model pracuje (dane meteorologiczne oraz emisyjne).



Rys. 1. Wykorzystanie modelu prognostycznego w systemie wspomagania decyzji.

Badania niepewności prognoz modeli mogą dotyczyć kilku aspektów: (a) oceny ilościowej (o ile jest ona możliwa) całkowitego (wypadkowego) zakresu niepewności prognoz modelu, wynikającego z działania wielu czynników, (b) zidentyfikowania głównych źródeł niepewności modelu i określenia ich względnego udziału w wypadkowej niepewności prognoz, (c) określenia zakresów parametrów modelu oraz danych wejściowych gwarantujących uzyskanie dokładnych wyników, (d) określenia warunków (wielkość obszaru, dyskretyzacja,

dokładność inwentaryzacji emisji, dokładność danych wejściowych i kluczowych parametrów modelu), dla których prognozy modelu można traktować jako najlepsze.

Dodatkowym utrudnieniem są problemy z oceną dokładności prognoz modelu, co wynika z błędów pomiarów, ograniczonego (niepełnego) zwykle zestawu danych pomiarowych (stężeń lub depozycji), które porównywane są z prognozami modelu w celu oszacowania jego dokładności. Z drugiej strony, wyniki generowane przez model są w wielu przypadkach „nieobserwowalne” (niemierzalne lub trudne do zmierzenia) w praktyce [1-4,14]. Wynika to m.in. z faktu, że wielkości wyjściowe obliczane przez model dotyczą danych zagregowanych, uśrednionych względem zmiennych przestrzennych oraz czasu, natomiast pomiar dotyczy z reguły wielkości punktowych.

W licznych pracach poświęconych tym zagadnieniom uważa się, że głównym źródłem niepewności zawartej w prognozach modelu są dane wejściowe. W większości publikacji przeważa natomiast pogląd [8–12], że dane emisyjne stanowią jedno z najpoważniejszych, jeżeli nie najpoważniejsze, źródło niepewności w modelowaniu rozprzestrzeniania się zanieczyszczeń atmosferycznych, niezależnie od zastosowanego modelu. Są w związku z tym zasadniczym ograniczeniem, jeżeli chodzi o możliwość zwiększenia dokładności generowanych prognoz.

W zależności od przeznaczenia i skali modelu, dane emisyjne mogą dotyczyć różnych kategorii źródeł (energetyka, przemysł, transport, sektor komunalno-bytowy, rolnictwo), z których każda charakteryzuje się nieco innym poziomem niepewności dotyczącej wielkości emisji:


- a) wysokie źródła punktowe (energetyka) – opis jest stosunkowo dokładny, ale wskazane jest uwzględnienie w modelu początkowego wyniesienia smugi zanieczyszczeń,
- b) średniej wysokości źródła punktowe (głównie przemysł) – większa niepewność w opisie emisji (charakterystyki techniczne i parametry paliwa często nie są dokładnie znane),
- c) źródła powierzchniowe (głównie sektor komunalno-bytowy) – duża niepewność – dane emisyjne są szacowane na podstawie rodzaju i wielkości zużycia paliw,
- d) źródła liniowe (sieć komunikacyjna) – duża niepewność (emisja zależy od natężenia ruchu, jakości paliwa, ale też od charakterystyk technicznych i wieku samochodów).

Charakterystyki dużych źródeł energetycznych są stosunkowo dokładne, również w odniesieniu do danych emisyjnych (znana technologia oraz generowana moc, dokładnie opisany proces spalania oraz parametry paliwa). Poziom niepewności jest większy w przypadku źródeł przemysłowych, zwłaszcza mniejszych zakładów (duża niepewność, co do parametrów używanego paliwa oraz samego procesu technologicznego). Bardzo duża niepewność dotyczy natomiast danych n.t. transportu samochodowego (co szczególnie wpływa na prognozę zanieczyszczeń w dużych miastach, czy aglomeracjach miejsko-przemysłowych), a zwłaszcza emisji sektora komunalno-bytowego, gdyż większość danych uzyskiwana jest w tym przypadku na podstawie zgrubnych (z konieczności) szacunków.

Najczęściej stosowanymi metodami analizy wrażliwości oraz oceny niepewności prognoz modeli zanieczyszczeń są: analiza wrażliwości wyników ze względu na zmiany parametrów modelu, analiza niepewności (ze względu na dane wejściowe) oparta na wykorzystaniu tzw. „małych zaburzeń” lub podejścia typu „brute-force” z wykorzystaniem algorytmu Monte Carlo [3,6,11]. Ta ostatnia metodologia została zastosowana w omawianym zadaniu.

2. Opis matematyczny procesów transportu zanieczyszczeń

Obecnie istnieje i jest stosowanych wiele rodzajów modeli prognostycznych, dostosowanych odpowiednio do skali miejskiej lub regionalnej [5,12]. Pomimo dużej ich różnorodności, większość tych realizacji ma pewne cechy wspólne. W szczególności, uwzględniają one podstawowe procesy mające wpływ na transport zanieczyszczeń, które przedstawiono schematycznie na rys. 2.



Rys. 2. Najważniejsze procesy w transporcie zanieczyszczeń [12].

Stosowany w tym przypadku opis matematyczny, obejmujący procesy transportu, dyspersji i przemian zanieczyszczeń przyjmuje postać układu równań adwekcji-dyfuzji, w ogólnej postaci

$$\frac{\partial c_i}{\partial t} + \nabla \cdot \vec{U} c_i = \nabla \rho D \nabla (c_i / \rho) + R_i(c_1, c_2, \dots, c_n, t) + S_i(\vec{x}, t), \quad (1)$$

dla $i = 1, 2, \dots, n,$

z odpowiednimi warunkami początkowymi i brzegowymi. W układzie równań (1) c_i oznacza stężenie substancji i ; \vec{U}_i – wektor pola wiatru; D – współczynnik dyfuzji; R_i – współczynniki przemian reakcji chemicznych poszczególnych zanieczyszczeń; $S_i(x, t)$ – wielkość emisji

lub redukcji substancji i dla ustalonej lokalizacji przestrzenno-czasowej; ρ – gęstość powietrza. Większość parametrów równań zależy od aktualnych warunków meteorologicznych.

Realizacja komputerowa w większości stosowanych dzisiaj modeli oparta jest [7] na jednym z dwóch podstawowych rozwiązań: lagranżowskim lub eulerowskim. Historycznie wcześniejsze modele lagranżowskie oparte są na analizie transportu, wyemitowanej ze źródła masy zanieczyszczeń, wzdłuż trajektorii pola wiatru, z uwzględnieniem procesów przemian fizyko-chemicznych, którym w tym czasie podlegają. Wynikiem jest wartość stężenia lub depozycji w wybranym receptorze.

Przyjęcie jednego z tych rozwiązań wynika przede wszystkim z przeznaczenia modelu oraz jego prognoz. Wymagania sprzętowe oraz czasochłonność obliczeń są oczywiście znacznie mniejsze w przypadku modeli lagranżowskich, co ma istotne znaczenie w modelach tzw. operacyjnych, czyli przeznaczonych do bieżącego wspomagania decyzji (zwłaszcza podejmowanych w czasie rzeczywistym). Główną ich zaletą, wykorzystywaną w konkretnych realizacjach (porównaj, np. model EMEP/RAINS [7,12]), jest możliwość niezależnej analizy poszczególnych źródeł emisji i tworzenia jednostkowych, tzw. *macierzy przeniesienia* źródło – receptor, które są wykorzystywane m.in. w analizie scenariuszy ograniczania emisji.

Obecnie, w najbardziej zaawansowanych modelach regionalnych i wieloskalowych (tzw. modelach III generacji), schemat eulerowski staje się najczęściej stosowanym rozwiązaniem (patrz np. nowa wersja modelu EMEP). Są to z reguły modele wielowarstwowe, oparte na pełnej aproksymacji przestrzenno-czasowej równań transportu. W celu uzyskania dokładniejszego opisu rzeczywistości uwzględniany jest często wpływ dodatkowych czynników meteorologicznych oraz procesów przemian fizyko-chemicznych zanieczyszczeń, czego wynikiem jest większą złożoność struktury matematycznej modelu. Wprowadzona parametryzacja tych czynników stanowi jednak dodatkowe źródło niepewności prognoz.

3. Wpływ danych wejściowych na jakość prognoz

Niezależnie od parametrów samego modelu, które zależą od skali przestrzenno-czasowej oraz przeznaczenia modelu, zasadnicze znaczenie dla dokładności generowanych wyników lub niepewności związanej z jego prognozami mają dane wejściowe. Można wśród nich wyróżnić kilka grup danych, jak zwłaszcza: prognoza meteorologiczna, dane emisyjne, topografia i dane fizjograficzne terenu. W szczególności dwie pierwsze grupy tych danych są wprowadzane w postaci pewnych rozkładów przestrzenno-czasowych, które są interpolowane do węzłów siatki obliczeniowej, z określonym krokiem czasowym. Między innymi z tego powodu (ale nie tylko) stanowią one bardzo istotne źródło niepewności prognoz modelu.

3.1 Niepewność elementów prognozy meteorologicznej

Prognoza meteorologiczna stanowiąca wejście do modelu transportu zanieczyszczeń (m.in. rozkład pola wiatru, wysokość warstwy mieszania, wilgotność, temperatura, zachmurzenie, intensywność opadów) jest obarczona błędami. Jest ona wynikiem dość złożonego procesu tzw. asymilacji danych [6,7], w którym uwzględnia się wyniki: (a) pomiarów wykonywanych jedynie w wybranych, stosunkowo nielicznych węzłach obszaru i w określonych chwilach czasowych, często wykonywanych różnymi technikami, (b) prognozy

numerycznej na kolejny krok czasowy oraz (c) analizy, której celem jest uzyskanie pełnego obrazu rozkładu przyjętych parametrów meteorologicznych we wszystkich węzłach siatki obliczeniowej, uwzględniającej zarówno wyniki pomiarów jak i prognozę numeryczną. Otrzymany rozkład pól meteorologicznych stanowi tzw. tło, czyli warunki początkowe do wykonania kolejnego kroku prognozy numerycznej. Poszczególne elementy tej procedury przedstawiono dokładniej w [6].

Zarówno tło jak i pomiar przedstawiają pewien przybliżony obraz atmosfery, przy czym w przypadku pomiaru jest to informacja bezpośrednia, a w przypadku tła – wartości symulowane przez model numeryczny na podstawie pomiarów wcześniejszych. Oba te elementy są obarczone błędami. Z jednej strony wchodzi tu w grę błąd reprezentacji, zarówno danych pomiarowych, jak i modelu numerycznego. Pomiar jest wykonywany jako chwilowy i w wybranych, stosunkowo nielicznych punktach obszaru, natomiast model reprezentuje skończenie-wymiarowe przybliżenie ciągłych i bardzo złożonych procesów atmosferycznych. Poza tym dochodzą błędy o charakterze losowym, dotyczące zarówno danych pomiarowych jak i prognozy numerycznej. Wszystkie rodzaje błędów składają się na niepewność generowanej prognozy meteorologicznej.

Niezależnie od błędów samej prognozy meteorologicznej, dodatkowym źródłem niepewności wyników jest proces przeniesienia (interpolacji) tych danych na siatkę dyskretyzacji obszaru, w której działa model transportu zanieczyszczeń, a która z reguły nie pokrywa się z siatką modelu meteorologicznego.

Inny problem pojawia się w przypadku badania wrażliwości lub niepewności prognoz modelu z punktu widzenia wejściowych danych meteorologicznych [6,12,14]. Tego typu analiza jest najczęściej prowadzona w oparciu o metody Monte Carlo, co w tym wypadku oznacza konieczność symulowanie odpowiednio dużego zestawu scenariuszy meteorologicznych. Jednym z elementów takiego scenariusza, mającym największy wpływ na wyniki modelu, jest kierunek wiatru. W przypadku asymilacji danych pomiarowych musi być uwzględniony warunek ciągłości strumienia mas powietrza i ten sam warunek muszą spełniać wszystkie scenariusze stanowiące wejście dla algorytmu Monte Carlo. Niespełnienie tego warunku może prowadzić do konstruowania całkowicie nierealistycznego rozkładu pola wiatru. W wyjściowym rozkładzie zanieczyszczeń powietrza (np. stężenia zanieczyszczeń) fakt ten objawia się w postaci pewnych regionów o niezwykle wysokich/niskich wartościach stężeń, które nie mają żadnego fizycznego uzasadnienia.

3.2 Dane meteorologiczne a parametry równań transportu

W równaniach transportu zanieczyszczeń postaci (1) występują bezpośrednio lub pośrednio parametry meteorologiczne, od których zależy sposób rozprzestrzeniania się zanieczyszczeń, ich zasięg przestrzenny, wartości stężenia lub depozycji w poszczególnych punktach obszaru oraz ostateczne ich oddziaływanie na środowisko.

Standardowe dane meteorologiczne takie jak np.: prędkość i kierunek wiatru, temperatura, nasłonecznienie, intensywność opadu oddziałują bezpośrednio na propagację oraz czasowo-przestrzenny rozkład zanieczyszczeń. Niektóre z tych parametrów (wektor pola wiatru, opad) występują bezpośrednio w równaniach postaci (1). Inne natomiast procesy, bardzo istotne z punktu widzenia transportu zanieczyszczeń (porównaj rys. 2), są ujmowane w tych równaniach poprzez odpowiednią parametryzację.

Pionowy profil pola wiatru

Pole wiatru w modelowanym obszarze wynika bezpośrednio z rozkładu ciśnienia, jednak kierunek i wartość wektora wiatru zależy od wysokości nad powierzchnią ziemi (skręt wiatru z wysokością [7]). Warstwa troposfery analizowana w modelach transportu zanieczyszczeń, to tzw. *warstwa mieszania* o wysokości H_m , która może być ustalona lub zmienna przestrzennie, w zależności od konstrukcji modelu (porównaj [6,7]).

Wiatr *geostroficzny* w_g , wiejący na górnej granicy warstwy mieszania, wynika bezpośrednio z rozkładu ciśnienia, natomiast w miarę zbliżania się do powierzchni ziemi, wskutek oddziaływania siły tarcia (wzajemnego tarcia warstw powietrza oraz tarcia o powierzchnię ziemi) oraz siły Coriolisa, następuje osłabienie oraz skrócenie kierunku wiatru. Jeżeli na podstawie prognozy meteorologicznej znany jest *wiatr anemometryczny* (na wysokości anemometru) w_a oraz geostroficzny w_g , pionowy profil pola wiatru może być opisany przez układ równań tzw. spirali Ekmana [5,7,12]:

Wektory $w_g = [u_g, v_g]$ oraz $w_a = [u_a, v_a]$ reprezentują, odpowiednio, wiatr geostroficzny oraz anemometryczny (uśrednione dane pomiarowe na wysokości anemometru), natomiast \bar{e} oznacza uśrednioną w modelowanym obszarze elewację terenu, f – współczynnik Coriolisa, K_m – funkcję uniwersalną zależną od warunków stabilności atmosfery [7].

Jeżeli model transportu zanieczyszczeń wykorzystuje jako dane wejściowe w_g, w_a oraz H_m , przy czym ostatnia wielkość nie jest elementem standardowej prognozy meteorologicznej (jej wartość jest na ogół szacowana na podstawie innych parametrów meteorologicznych) – dane te stanowią one istotne źródło niepewności prognoz modelu.

Stan równowagi atmosfery

Innym, bardzo istotnym elementem warunków pogodowych, który również nie wchodzi w skład standardowej prognozy meteorologicznej, jest stan równowagi atmosfery (tzw. *stabilność atmosferyczna*). Jest ona związana bezpośrednio z pionowym profilem temperatury w warstwie mieszania, od którego bezpośrednio zależy, w jaki sposób przebiega proces rozprzestrzeniania się zanieczyszczeń w obszarze. W opracowaniach [6,7] przedstawiono schematycznie kształt smugi zanieczyszczeń emitowanych ze źródła punktowego w zależności od warunków termicznych.

Ruchy konwekcyjne cząsteczki zanieczyszczeń zależą od ich temperatury względem otaczającego powietrza; jeżeli temperatura zanieczyszczeń jest wyższa – unoszą się one, w przeciwnym przypadku – opadają. W związku z tym, decydujące znaczenie ma przebieg pionowego gradientu temperatury powietrza w stosunku do tzw. gradientu *sucho-adiabatyicznego* (przemiany w gazach zachodzą bez wymiany ciepła z otoczeniem), który stanowi wartość referencyjną. Gradient sucho-adiabatyiczny oznacza spadek temperatury powietrza w funkcji wysokości o ok. 1 °C na każde 100

Jeżeli aktualny gradient temperatury otaczającego powietrza (porównaj rys. 8 w [6]) jest większy od sucho-adiabatyicznego, atmosfera jest w stanie niestabilnym, tzn. wzmocniane będą

pionowe ruchy zanieczyszczeń emitowanych ze źródeł (np. będą się stale unosić, ponieważ ich temperatura jest wyższa niż temperatura otoczenia). W przeciwnym wypadku, jeżeli gradient temperatury otoczenia jest mniejszy niż sucho-adiabatyyczny – warunki są stabilne, tzn. wszelkie ruchy pionowe emitowanych zanieczyszczeń są tłumione w wyniku istniejącej różnicy temperatur. Jeżeli natomiast gradient temperatury otoczenia jest zbliżony do adiabatycznego – panują warunki neutralne. Poza tym, możemy w praktyce mieć do czynienia z kombinacją różnych warunków, jeżeli pojawia się inwersja temperatury. Graficzną ilustrację tych przypadków przedstawia rys.8 zamieszczony w [6].

W większości implementacji modeli transportu zanieczyszczeń stabilność atmosferyczna uwzględniana jest poprzez wprowadzenie tzw. klasyfikacji Pasquilla, który wprowadził 6 klas tego parametru, zgodnie z tabelą przedstawioną m.in. w [5,6,7].

Parametr ten nie jest wyznaczany bezpośrednio jako element standardowej prognozy meteorologicznej, lecz jest szacowany na podstawie innych elementów prognozy. Zgodnie ze stosowanymi procedurami, zależy on m.in. od prędkości wiatru, pory dnia, zachmurzenia, nasłonecznienia i jego wartość jest wyznaczana na podstawie tych danych [7,15]. Z drugiej strony, odgrywa on bardzo istotną rolę w modelach transportu zanieczyszczeń, bo od jego wartości zależą z kolei warunki mieszania turbulencyjnego (pionowego i poziomego) zanieczyszczeń. To z kolei przekłada się na ostateczny rozkład stężenia i zasięg oddziaływania zanieczyszczeń.

Tak więc jest oczywiste, że w kompleksowej analizie niepewności i nieprecyzyjności prognoz modeli rozprzestrzeniania się zanieczyszczeń atmosferycznych, niepewność określania stanu równowagi atmosfery powinna być bezwzględnie brana pod uwagę.

3.3 Dane emisyjne

W większości publikacji przeważa pogląd [1,2,8,12,13], że dane emisyjne stanowią jedno z najpoważniejszych, jeżeli nie najpoważniejszych, źródeł niepewności w modelowaniu rozprzestrzeniania się zanieczyszczeń atmosferycznych, niezależnie od zastosowanego modelu. Są w związku z tym zasadniczym ograniczeniem, jeżeli chodzi o możliwość zwiększenia dokładności generowanych prognoz. Podstawowa niepewność dotyczy samej wielkości emisji źródła, która bardzo często jest określana na podstawie szacunków, jednak w przypadku niektórych kategorii źródeł na niepewność prognozy mogą mieć wpływ również parametry techniczne emitora.

W zależności od modelowanego obszaru i przeznaczenia modelu, dane emisyjne mogą dotyczyć różnych kategorii źródeł (energetyka, przemysł, transport samochodowy, sektor komunalno-bytowy, rolnictwo), z których każda charakteryzuje się nieco innym poziomem niepewności dotyczącej wielkości emisji:

- a) wysokie źródła punktowe (energetyka) – opis stosunkowo dokładny, ale konieczność uwzględnienia w modelu początkowego wyniesienia smugi zanieczyszczeń (patrz poniżej),
- b) średniej wysokości źródła punktowe (głównie przemysł) – większa niepewność w opisie emisji (charakterystyki techniczne i paliwo nie są dokładnie znane),
- c) źródła powierzchniowe (głównie sektor komunalno-bytowy) – duża niepewność – dane emisyjne szacowane na podstawie zużycia paliwa,

d) źródła liniowe (sieć komunikacyjna) – duża niepewność (emisja zależy od natężenia ruchu, paliwa, ale też od charakterystyk technicznych i wieku samochodów).

Charakterystyki źródeł energetycznych są stosunkowo dokładne, również w odniesieniu do danych emisyjnych (znana technologia oraz generowana moc, opisany proces spalania i parametry paliwa). Poziom niepewności jest większy w przypadku źródeł przemysłowych, zwłaszcza mniejszych zakładów. Bardzo duża niepewność towarzyszy natomiast danym dotyczącym transportu samochodowego (np. w dużych miastach, aglomeracjach miejsko-przemysłowych), a zwłaszcza emisji sektora komunalno-bytowego, gdyż większość danych uzyskiwana jest w tym przypadku na podstawie szacunków. Podobnie, bardzo trudnym do dokładnego opisanego pola emisji jest sektor rolniczy, gdzie duża niepewność towarzyszy, np. inwentaryzacji źródeł emisji amoniaku.

Parametryzacja początkowego kształtu smugi zanieczyszczeń

W przypadku wysokich, punktowych źródeł emisji (LCP – *Large Combustion Plants*) wysokość tzw. pozornego punktu emisji – H obliczana jest na podstawie wysokości kominy – h , jego średnicy wewnętrznej – d , temperatury gazów odlotowych – T oraz ich prędkości – v_d . W zależności od ilości ciepła emitowanego z kominy – $Q(T)$ stosowane są dwie metody obliczania wyniesienia smugi, Hollanda i CONCAWE [6,15].

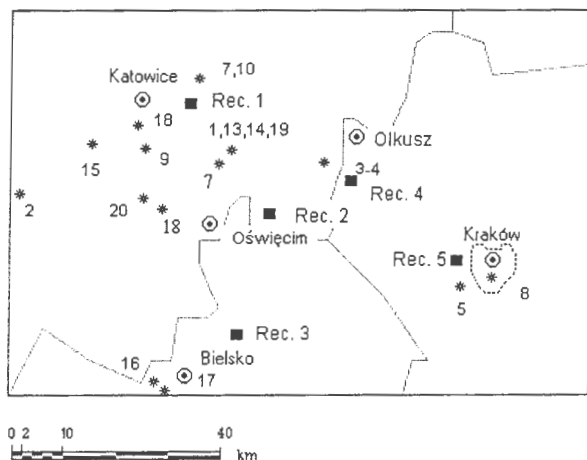
Występujący w tych formułach parametr u_h – prędkość wiatru na wysokości emitora, wpływa dodatkowo na przesunięcie pozornego punktu emisji zgodnie z kierunkiem wiatru oraz rozkład przestrzenny smugi zanieczyszczeń.

W przypadku stosowania tych formuł, obok parametrów dotyczących wielkości emisji, potencjalne źródła niepewności stanowią temperatura oraz prędkość gazów odlotowych, których wartości użyte w obliczeniach mogą podlegać fluktuacjom w czasie oraz być obciążone błędami. Ten fakt wzięto pod uwagę w obliczeniach kontrolnych.

4. Niepewność w prognozowaniu rozkładów stężeń

4.1. Wyniki obliczeń testowych

Obliczenia testowe dotyczyły oceny niepewności prognoz przeprowadzono na przykładzie regionalnego, trójwarstwowego modelu eulerowskiego REGFOR3 [5,6]. Rozważano prostokątny obszar obliczeniowy o wymiarach 110 km x 76 km obejmujący Górny Śląsk oraz region Krakowa. Rozważano emisję oraz rozprzestrzenianie się dwutlenku siarki, przy czym jako analizowane źródła przyjęto 20 największych zakładów energetyki zawodowej zlokalizowanych w tym regionie. Dla celów obliczeniowych, obszar zdyskretyzowano jednorodną siatką kwadratową o kroku $h = 2$ km. Na rys. 3 przedstawiony jest obszar obliczeniowy, lokalizacja analizowanych źródeł emisji oraz 5-ciu hipotetycznych receptorów, w których rejestrowane były wyniki obliczeń. W tych punktach rejestrowano m.in. rozkłady prognozowanych przez model średnio-sezonowe wartości stężenia SO_2 oraz rozkłady tego stężenia charakteryzujące niepewność prognoz.



Rys. 3. Rozmieszczenie źródeł emisji oraz receptorów w obszarze obliczeniowym

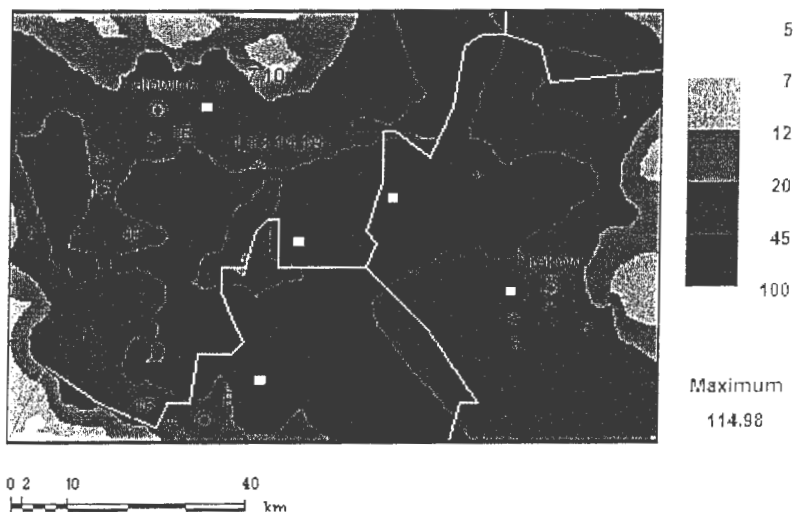
Do przeprowadzenia obliczeń dotyczących poziomu niepewności generowanych prognoz wykorzystano algorytm Monte-Carlo. Obliczenia były przeprowadzone dla sezonu zimowego (dane meteorologiczne oraz emisyjne z roku 2005), przy czym nominalne wartości emisji źródeł dla rozważanego okresu (obliczenia dotyczyły sezonu zimowego) są podane w tablicy 2. Przeprowadzone oddzielnie trzy części eksperymentu numerycznego dotyczyły odpowiednio wpływu: a) niepewności poziomu emisji źródeł, b) niepewności dotyczącej parametrów technicznych źródeł, c) niepewności podstawowych danych meteorologicznych. Ostateczne wyniki przedstawiają sumaryczną niepewność związaną z oddziaływaniem powyższych czynników.

W tablicy 3 podano zakres niepewności danych wejściowych, czyli wielkości emisji dwutlenku siarki oraz parametry techniczne dla 20 analizowanych źródeł oraz podstawowych parametrów meteorologicznych. Dla podanego zakresu niepewności oraz przyjętego rozkładu wygenerowano losowo 1000 zestawów badanych parametrów. W celu uniknięcia nierealistycznych epizodów meteorologicznych, założono korelację między wektorami wiatru przyziemnego i geostroficznego. Wstępne obliczenia były przeprowadzone dwukrotnie, odpowiednio dla rozkładu normalnego (N) oraz log-normalnego (L-N) dla wszystkich analizowanych zmiennych (w większości pozycji literaturowych [5,6,8,13] w analizie niepewności ze względu na dane emisyjne przyjmowany jest rozkład log-normalny). Ponieważ różnice w wynikach uzyskanych dla obu rozkładów były nieistotne (decydujące znaczenie miała szerokość przedziału niepewności, a nie sam rozkład), zasadnicze obliczenia przeprowadzono dla rozkładu normalnego.

Podstawowe obliczenia były przeprowadzone na procesorze Pentium Core2Duo (system operacyjny Linux). Kod źródłowy modelu REGFOR3 (Fortran90) kompilowany programem Lahey F90/95. Czas obliczeń jednej serii dla 1000 zestawów danych losowych wynosił 10 godzin, przy czym w jednym przebiegu generowana była prognoza długoterminowa (sezonowa), realizowana z krokiem 6-godzinny. Wyniki były rejestrowane jako uśrednione za okres symulacji (sezon zimowy) wartości stężenia SO₂ w 5-ciu receptorach zaznaczonych na rysunkach 3 oraz 4.

Tablica 2. Parametry źródeł emisji


No	Emitor	Współrzedne siatki.	He [m]	Emisja (zima) [t/d]	Emisja (lato) [t/d]
1	Jaworzno III	(21,24)	250	303.2	227.2
2	Rybnik	(1,20)	200	225.2	167.6
3	Siersza A	(30,23)	150	104.0	88.0
4	Siersza B	(30,23)	260	91.8	68.0
5	Skawina	(43,11)	120	90.1	58.6
6	Łaziska I	(8,20)	200	78.0	55.6
7	Będzin B	(18,31)	200	65.0	15.2
8	Łęg	(46,12)	250	52.0	37.2
9	Katowice	(13,25)	250	52.0	37.2
10	Będzin A	(18,31)	160	45.1	30.2
11	Łaziska II	(8,20)	160	34.7	23.1
12	Łaziska III	(8,20)	100	33.8	23.5
13	Jaworzno IIA	(21,24)	120	29.9	19.2
14	Jaworzno IIB	(21,24)	100	25.1	17.7
15	Halemba	(8,25)	110	26.0	17.3
16	Bielsko-Biała	(14,2)	140	18.7	11.2
17	Bielsko-Km.	(15,1)	250	16.9	7.5
18	Chorzów	(12,27)	100	15.1	7.5
19	Jaworzno I	(20,23)	152	12.3	6.8
20	Tychy	(13,19)	120	11.6	8.6




Rys. 4. Średnio-sezonalny rozkład stężenia SO_2 w obszarze (nominalne wartości emisji)

Tablica 3. Zakres zmienności danych wejściowych przyjęty w analizie niepewności


Parametr	Zakres niepewności (dla 95% danych)	Rozkład
Emisja [g/s]	$\pm 20\%$	N / L-N
Prędkość gazów odlotowych [m/s]	$\pm 15\%$	N / L-N
Temperatura gazów odlotowych [$^{\circ}$ K]	$\pm 15\%$	N / L-N
Wysokość warstwy mieszania [m]	$\pm 25\%$	N / L-N
Składowe wiatru geostroficznego [m/s]	$\pm 25\%$	N / L-N
Składowe wiatru przyziemnego [m/s]	$\pm 25\%$	N / L-N
Temperatura [$^{\circ}$ C]	$\pm 25\%$	N / L-N
Intensywność opadu [mm/h]	$\pm 25\%$	N / L-N
Klasa stabilności atmosfery [-]	± 1	Dyskr.




Rys. 5. Wpływ intensywności emisji na zakres niepewności prognoz stężenia SO₂.



Rys. 6. Wpływ emisji i parametrów źródła na zakres niepewności prognoz stężenia SO₂.



Rys. 7. Łączny wpływ danych emisyjnych i meteorologicznych na zakres niepewności prognoz stężenia SO₂ (bez uwzględnienia klasy stabilności).



Rys. 8. Łączny wpływ danych emisyjnych i meteorologicznych (z uwzględnieniem stabilności atmosferycznej) na zakres niepewności prognoz stężenia SO₂.

Na rysunkach 5–8 przedstawiono wybrane wyniki obliczeń dotyczące ostatecznych oszacowań zakresu niepewności prognoz stężenia SO_2 w 5-ciu analizowanych receptorach. Wyniki te są prezentowane w postaci standardowych wykresów „pudełkowych” (tzw. *box plot*) i dotyczą zakresu niepewności wyników, odpowiednio dla 50% oraz 90% danych. Pełne wyniki, zawierające wykresy dystrybuanty empirycznej oraz histogramy reprezentujące rozkład gęstości próbki dla każdego zanalizowanych czynników można znaleźć w [6].

Kolejne z czterech omawianych rysunków, dla każdego receptora ilustrują – odpowiednio – wpływ niepewności: a) intensywności emisji, b) emisji oraz parametrów technicznych emitora, c) pełnych danych emisyjnych oraz danych meteorologicznych (z wyłączeniem wpływu klasy stabilności atmosfery), d) oddzielnie pokazany wpływ niepewności w prognozowaniu klasy równowagi atmosfery. Zakładany zakres niepewności danych wejściowych dla poszczególnych parametrów był zgodny wartościami podanymi w tablicy 3.

Z rysunków 5-6 wynika, że wpływ intensywności emisji oraz parametrów technicznych źródła powoduje niepewność wyników nie przekraczającą 20% (dla 90% analizowanych danych). Z kolei, uwzględnienie dodatkowo niepewności danych meteorologicznych (rysunek 7) powoduje wzrost zakresu niepewności wyników do około 30%. Co więcej, zakresy niepewności rejestrowane we wszystkich 5-ciu receptorach są do siebie zbliżone.

Gwałtowny wzrost niepewności następuje natomiast po dodatkowym uwzględnieniu wpływu klasy równowagi atmosfery przy wejściowej niepewności tego parametru zgodnej z wartościami podanymi w tablicy 3. W tym wypadku dodatkowo pojawia się duże zróżnicowanie wyników w zależności od receptora. Największa rejestrowana niepewność wyników dotyczy receptorów nr 2 oraz 4 (odpowiednio, około $\pm 80\%$ oraz $\pm 63\%$), a najmniejsza – receptora nr 1 (około $\pm 30\text{--}45\%$).

Jest kilka przyczyn tak istotnego a równocześnie zróżnicowanego wpływu tego parametru, które należy brać pod uwagę. Rozważane w ramach tych obliczeń źródła należą do kategorii LCP (*Large Combustion Plants*), wysokich źródeł punktowych o bardzo dużej intensywności emisji. W tego typu emitatorach bardzo istotny wpływ na rozprzestrzenianie się zanieczyszczeń ma początkowe wyniesienie smugi, które może tu osiągać bardzo duże wartości (porównaj formuły Hollanda oraz CONCAWE [7,15]). W powiązaniu z wahaniami stanu równowagi atmosfery, daje to bardzo duże różnice w zasięgu oddziaływania danego źródła (przy zmianie klasy równowagi o ± 1 , maksymalne wartości stężeń mogą się przesuwać o kilkadziesiąt kilometrów). Przy dominujących wiatrach z kierunku PN-Z, receptor nr 2 jest w zasięgu oddziaływania największego źródła nr 1 (Jaworzno III, wysokość 250 m). To powoduje, że dystrybuanta oraz rozkład gęstości próbki dla tego receptora (patrz pełne wyniki prezentowane w [6]) pokazują występowanie 3 maksimum, co jest bezpośrednim odbiciem uwzględnienia na wejściu wahań w zakresie 3 sąsiednich klas stabilności atmosferycznej. Ostatecznym wynikiem jest oczywiście bardzo szeroki zakres niepewności wyjściowej. Analogiczna sytuacja dotyczy receptora nr 4, który jest w bezpośrednim zasięgu oddziaływania źródeł 3 oraz 4 (2 wysokie kominy elektrowni Siersza). Receptor 5 jest również w zasięgu oddziaływania dwóch ostatnich źródeł, ale za względu na znaczną odległość, efekt jest słabszy.

W tej analizie należy również uwzględnić wpływ parametryzacji stanu równowagi atmosfery, którą zastosowano w modelu transportu zanieczyszczeń. Wymaga to dokładniejszej analizy, bowiem może się okazać, że zastosowana parametryzacja przeszacowuje wpływ tego elementu prognozy, tzn. model jest zbyt wrażliwy na jego wahania.

4.2. Podsumowanie

Autorzy cytowanych pozycji literaturowych sugerują, że niepewność danych emisyjnych ma porównywalny lub nawet większy wpływ na dokładność wyników w porównaniu z danymi meteorologicznymi. Prezentowane tu wyniki wykazują, przynajmniej w niektórych punktach obszaru (odpowiadającym wysokim stężeniom), silniejszy wpływ danych meteorologicznych. Jedną z przyczyn tego typu rozkładów jest fakt, że rozważane źródła emisji, to duże zakłady energetyki zawodowej o znanych parametrach technologicznych procesu spalania, zużyciu paliwa i procentowej zawartości zanieczyszczeń (w tym zawartości siarki). Z tego względu przyjmuje się w takim przypadku stosunkowo wąski zakres niepewności odnoszący się do poziomu emisji. Znacznie szerszy zakres musi być natomiast uwzględniony w przypadku, np. źródeł powierzchniowych (sektor komunalno-bytowy) lub liniowych źródeł reprezentujących sieć komunikacyjną. W tych przypadkach dane emisyjne są z reguły oparte na zagregowanych informacjach szacunkowych, co wymaga założenia znacznie szerszego zakresu niepewności.

Z drugiej strony, w wyniku zastosowanej w modelu parametryzacji niektórych procesów, analizowane w obliczeniach dane meteorologiczne często wpływają pośrednio na to, w jaki sposób proces dyspersji zanieczyszczeń jest przez model realizowany. W szczególności, wahania prędkości wiatru lub wysokości warstwy mieszania mają bezpośredni wpływ na procesy dyfuzji turbulencyjnej (horyzontalnej i pionowej), a więc także na wymianę zanieczyszczeń między warstwami. To z kolei przenosi się na warunki rozprzestrzeniania się zanieczyszczeń i ostateczne wartości stężeń.

Wpływ poszczególnych grup parametrów wejściowych na niepewność wyników zależy w dużym stopniu od przeznaczenia modelu. Jeżeli jest on wykorzystywany do prognoz krótkoterminowych lub, w szczególności, do sterowania emisją w czasie rzeczywistym, należy liczyć się z dużym wpływem niepewności danych meteorologicznych. W tym przypadku dane te muszą być bowiem wprowadzane jako rzeczywista prognoza, a więc będą równocześnie odbiciem niepewności tej prognozy. W przypadku analizy z długim horyzontem czasowym (np. rocznej lub wieloletniej) parametry meteorologiczne są z reguły oparte na rzeczywistych danych pomiarowych z tego okresu (danych historycznych), więc głównym źródłem niepewności stają się źródła emisji.

Przedstawione wyniki są podstawą do dalszych analiz, dotyczących m.in. wpływu niepewności prognoz jakości powietrza atmosferycznego na proces podejmowania decyzji. W prowadzonych obecnie pracach badany jest wpływ parametrów samego modelu oraz łączny wpływ różnych kategorii danych wejściowych na końcową dokładność prognoz oraz rozwiązań opartych na tym modelu zadań optymalizacyjnych. Jedną z kategorii takich zadań, rozważana we wcześniejszych opracowaniach [5], dotyczyła optymalnego wyboru technologii ograniczania emisji w wytypowanych źródłach, która umożliwia, np. osiągnięcie założonego standardu jakości powietrza przy minimalnych nakładach finansowych na realizację tych technologii. We wspomnianych pracach zakładano ustalone, nominalne wartości emisji wszystkich rozważanych źródeł i dla takich wartości wyznaczane było rozwiązanie optymalne. Uwzględnienie dodatkowo zakresu niepewności w prognozowanych wartościach stężeń pozwoli oszacować, w jakim stopniu niepewność danych wejściowych oraz parametrów modelu znajduje odbicie w rozwiązaniach zadań optymalizacyjnych. Wyniki tego typu analizy przedstawiono w następnym rozdziale.

5. Analiza niepewności w rozwiązaniach zadań decyzyjnych

5.1. Sformułowanie zadania - wybór strategii ograniczenia emisji

Rozważane zadanie polega na osiągnięciu założonego standardu jakości środowiska przy minimalnych nakładach finansowych, poprzez odpowiedni wybór technologii ograniczających emisję SO_2 w źródłach oddziaływujących na dany obszar. Analiza opiera się na założeniu liniowej zależności stężenia dwutlenku siarki pochodzącej z danego źródła od wielkości jego emisji. Takie założenie pozwala dla każdego źródła wyznaczyć w trybie *off-line* macierz relacji emisja-stężenie. Macierze takie (tzw. *macierze przeniesienia*) określają rozkład stężenia zanieczyszczeń w regionie w odniesieniu do jednostkowej emisji każdego ze źródeł i są następnie wykorzystywane w procedurze wyboru technologii odsiarczania [5].

Zakładamy, że w regionie Ω jest rozmieszczonych N dużych źródeł emisji SO_2 i dodatkowo pewna liczba mniejszych źródeł punktowych i powierzchniowych, tworzących tło stężenia. Dysponujemy ponadto M technologiami redukcji emisji, przy czym każda z technologii jest charakteryzowana przez efektywność redukcji emisji i jednostkowe koszty (na jednostkę emisji) inwestycyjnych i eksploatacyjnych (operacji).

Zadanie polega na przydzieleniu technologii redukcji emisji do wszystkich rozpatrywanych obiektów, aby osiągnąć założony standard jakości środowiska przy minimalnych nakładach finansowe na odsiarczanie, w zadanym horyzoncie czasowym T . Używamy oznaczeń:

$\Omega = L_x \times L_y$ -- rozpatrywany region (prostokąt),

N – liczba rozpatrywanych źródeł,

M – liczba dostępnych technologii,

C – koszty całkowite (inwestycyjne i operacyjne) w jednym przedziale czasowym (roku),

$\vec{u} = [u_1, u_2, \dots, u_N]$ -- wektor emisji źródeł,

$\vec{e} = [e_1, e_2, \dots, e_M]$ -- wektor efektywności technologii redukcji,

$F = \{f_{ij}\}, 1 \leq i \leq N, 1 \leq j \leq M$ -- macierz kosztów redukcji na jednostkę emisji,

$X = \{x_{ij}\}, 1 \leq i \leq N, 1 \leq j \leq M$ -- macierz "0-1" przydziału technologii do źródeł (zmienne decyzyjne).

Funkcja strat środowiskowych, umożliwiająca porównywanie różnych scenariuszy redukcji emisji zanieczyszczeń, jest opisana w następujący sposób:

$$J(d) = \frac{1}{2} \int_{\Omega} w(x, y) [\max(0, d(x, y) - d_{ad})]^2 d\Omega \quad (2)$$

gdzie:

$w(x, y)$ – funkcja wrażliwości (wagi) terenu,

d_{ad} – dopuszczalny poziom stężenia SO_2 .

Prognoza stężenia zanieczyszczeń jest wyznaczana z zależności:

$$d(x, y) = d_0(x, y) + \sum_{i=1}^N A_i(x, y) \cdot u_i, \quad (x, y) \in \Omega, \quad (3)$$

gdzie:

$d_0(x, y)$ – stężenie pochodzące ze źródeł niesterowalnych (tło),

$A_i(x, y)$ – macierz przejścia (relacja emisja \rightarrow stężenie) i -tego źródła.

Macierz $A_i(x, y)$ reprezentuje udział i -tego źródła w sumarycznym polu stężenia, odnoszany się do jednostkowej wartości jego emisji. Wszystkie macierze $A_i(x, y)$ ($i=1, \dots, N$) są wyznaczane przez model prognostyczny dla zadanego scenariusza meteorologicznego w trybie *off-line*, tzn. przed rozpoczęciem procesu alokacji. W podobny sposób oblicza się stężenie tła zanieczyszczeń, czyli $d_0(x, y)$, pochodzące ze źródeł nie modyfikowanych, z równoczesnym uwzględnieniem napływu zanieczyszczeń z sąsiednich regionów.

Bieżąca intensywność emisji i -tego źródła zależy od emisji początkowej i efektywności zastosowanej technologii redukcji emisji:

$$u_i = u_i^0 \sum_{j=1}^M (1 - e_j) \cdot u_i, \quad \sum_{j=1}^M x_{ij} = 1, \quad x_{ij} \in \{0,1\}, \quad 1 \leq i \leq N, \quad (4)$$

gdzie:

u_i – bieżąca emisja i -tego źródła,

u_i^0 – początkowa emisja i -tego źródła.

Koszty redukcji emisji w każdym źródle składają się z kosztów inwestycyjnych i kosztów operacyjnych. Obydwa składniki kosztów zależą od przydzielonej do źródła technologii redukcji emisji i charakterystyki instalacji tej technologii w źródle. W dalszym ciągu przyjmujemy upraszczające założenie, że koszty inwestycyjne związane z wprowadzeniem j -tej technologii do i -tego źródła są podane jako uśrednione koszty roczne w całym procesie inwestycyjnym. Można zatem zapisać, że całkowite koszty redukcji emisji w jednym przedziale czasowym dla wszystkich źródeł w postaci muszą spełniać poniższe ograniczenie

$$C = \sum_{i=1}^N c_i = \sum_{i=1}^N u_i^0 \sum_{j=1}^M f_{ij} \cdot x_{ij} = \sum_{i=1}^N u_i^0 \sum_{j=1}^M (f_{ij}^1 + f_{ij}^2) \cdot x_{ij}, \quad (5)$$

gdzie

f_{ij} – uśrednione roczne koszty wprowadzenia j -tej technologii do i -tego źródła,

f_{ij}^1 – uśrednione roczne koszty inwestycyjne wprowadzenia j -tej technologii do i -tego źródła,

f_{ij}^2 – uśrednione roczne koszty operacyjne wprowadzenia j -tej technologii do i -tego źródła.

Rozpatrywane dalej zadanie optymalizacyjne ma charakter całkowitoliczbowy. Jest to zadanie przydziału technologii ograniczenia emisji do poszczególnych i źródeł może być w sposób formalny zapisane w postaci

ZADANIE ALOKACJI (ZA): Określić zbiór technologii ograniczenia emisji

$$X^* = \{x_{ij}^* \in \{0,1\}; \sum_{j=1}^M x_{ij}^* = 1, 1 \leq i \leq N, 1 \leq j \leq M\}$$

w taki sposób, aby zminimalizować koszt całkowity operacji

$$C_o = \sum_{i=1}^N c_i = \sum_{i=1}^N u_i^0 \sum_{j=1}^M f_{ij} \cdot x_{ij} \Rightarrow \min$$

w celu osiągnięcia założonego standardu jakości środowiska

$$J(d^*) \leq J_o.$$

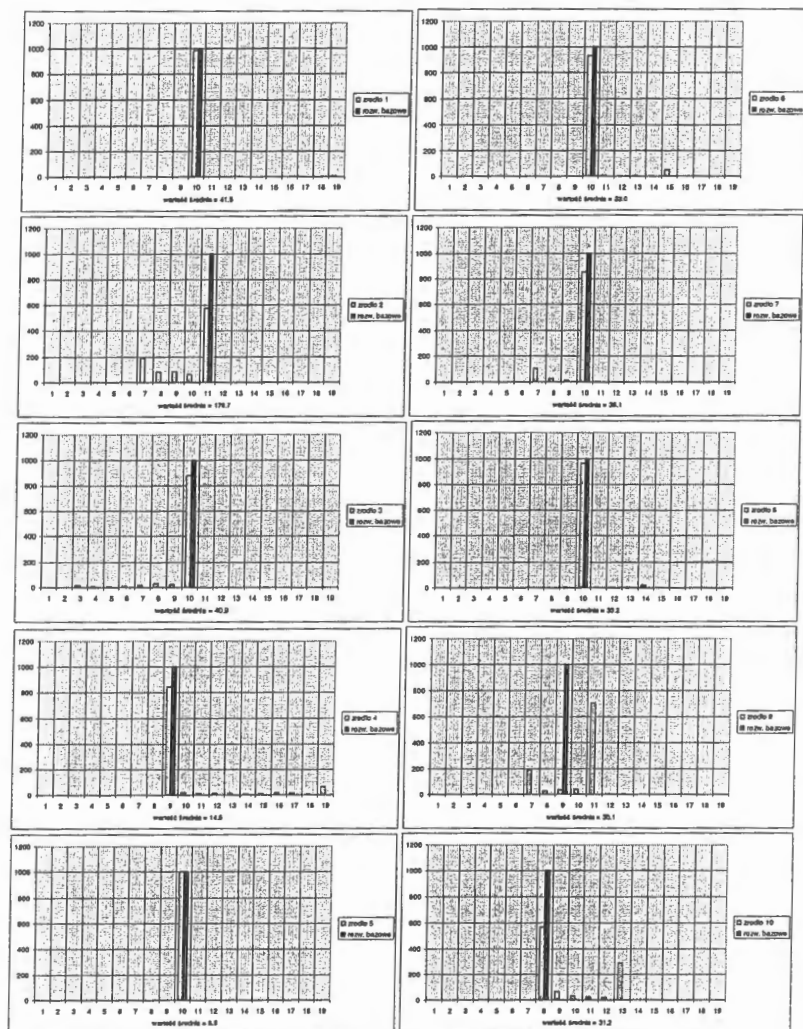
Do obliczania wartości wskaźnika strat środowiskowych J wykorzystano macierze przeniesienia wyznaczone na podstawie prognoz modelu komputerowego REGFOR3 omówionego m.in. w pracy [5]. Do rozwiązania samego zadania optymalizacyjnego zastosowano, omówiony i również [5] algorytm gradientowy, przy czym zadanie sformułowano jako zadanie ciągłe. Jego rozwiązanie zostało następnie wykorzystane do oceny dokładności metody stanowiącej przedmiot niniejszej pracy.

W kolejnym paragrafie przedstawiono wyniki analizy, której celem jest oszacowanie, w jaki sposób niepewność danych wejściowych modelu propagacji zanieczyszczeń wpływa na rozwiązanie zadania optymalizacyjnego (ZA).

5.2. Analiza niepewności -- wyniki obliczeń

Niepewność i nieprecyzyjność danych wejściowych (emisyjnych oraz meteorologicznych) implikuje niepewność wynikających stąd prognoz modelu rozprzestrzeniania się zanieczyszczeń, a więc generowanych przez ten model rozkładów stężenia. Z kolei te nieprecyzyjne wartości stężeń są wykorzystywane jako dane wejściowe w algorytmie optymalizacyjnym, którego celem jest znalezienie najlepszej strategii ograniczania emisji. Celem przeprowadzonych obliczeń było zatem określenie wpływu niepewności danych wejściowych na jakość (niepewność, nieprecyzyjność) ostatecznego rozwiązania zadania optymalizacyjnego, które sformułowano w poprzednim paragrafie. Należy oczywiście brać pod uwagę fakt, że rozwiązanie zadania wyboru technologii ma charakter całkowitoliczbowy i do tego typu zadania ma odnosić się ta ocena.

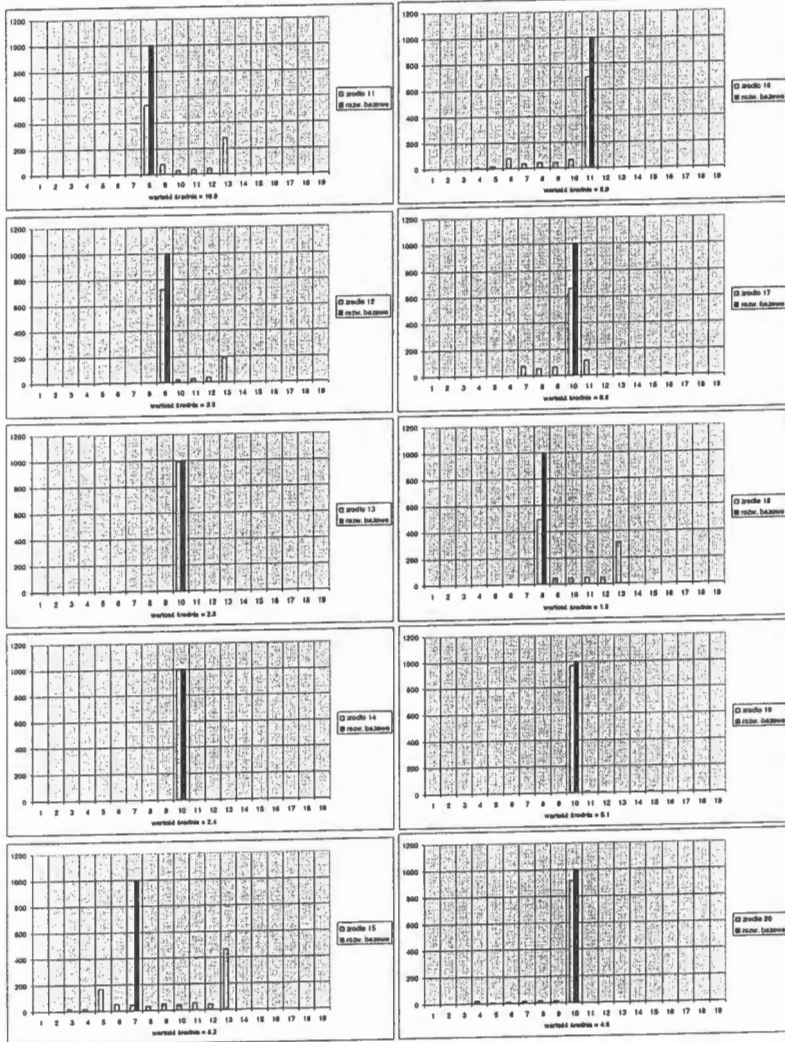
Jak wspomniano wcześniej, zastosowany do rozwiązania (ZA) algorytm bazuje na macierzach przeniesienia, generowanych off-line przez model REGFOR3 [5], reprezentujących jednostkowe rozkłady stężenia dla każdego ze źródeł emisji. Wobec tego przedstawione w rozdziale 4 oszacowania niepewności prognoz samego modelu transportu zanieczyszczeń nałożono na bazowe rozkłady macierzy przeniesienia. Zostały one następnie wykorzystane w procedurze Monte Carlo (wykonano 1000 iteracji), której tym razem użyto do określenia niepewności wyników samego algorytmu optymalizacyjnego.



Kategorie:

1) 0.0 - 0.15	6) 0.55 - 0.65	11) 1.05 - 1.15	16) 1.55 - 1.65
2) 0.15 - 0.25	7) 0.65 - 0.75	12) 1.15 - 1.25	17) 1.65 - 1.75
3) 0.25 - 0.35	8) 0.75 - 0.85	13) 1.25 - 1.35	18) 1.75 - 1.85
4) 0.35 - 0.45	9) 0.85 - 0.95	14) 1.35 - 1.45	19) 1.85 - 1.95
5) 0.45 - 0.55	10) 0.95 - 1.05	15) 1.45 - 1.55	

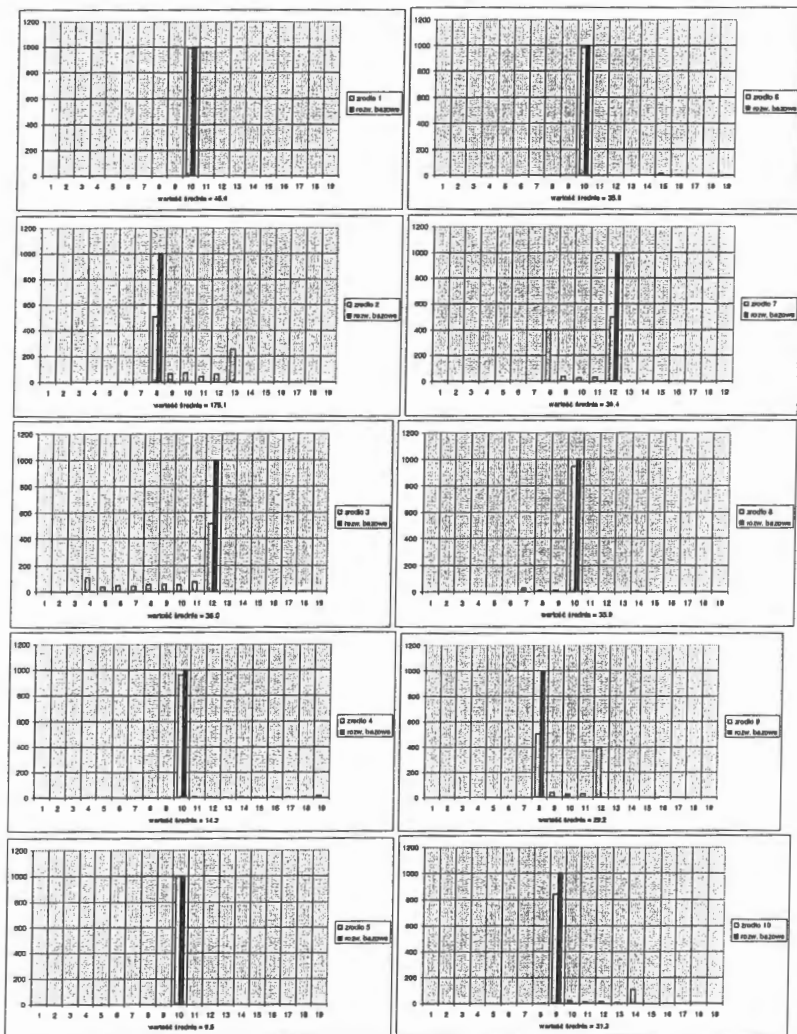
Rys. 9a. Histogram emisji źródeł 1-10 dla rozwiązania optymalnego ($J_p = 2.63 \cdot 10^6$)



Kategorie:

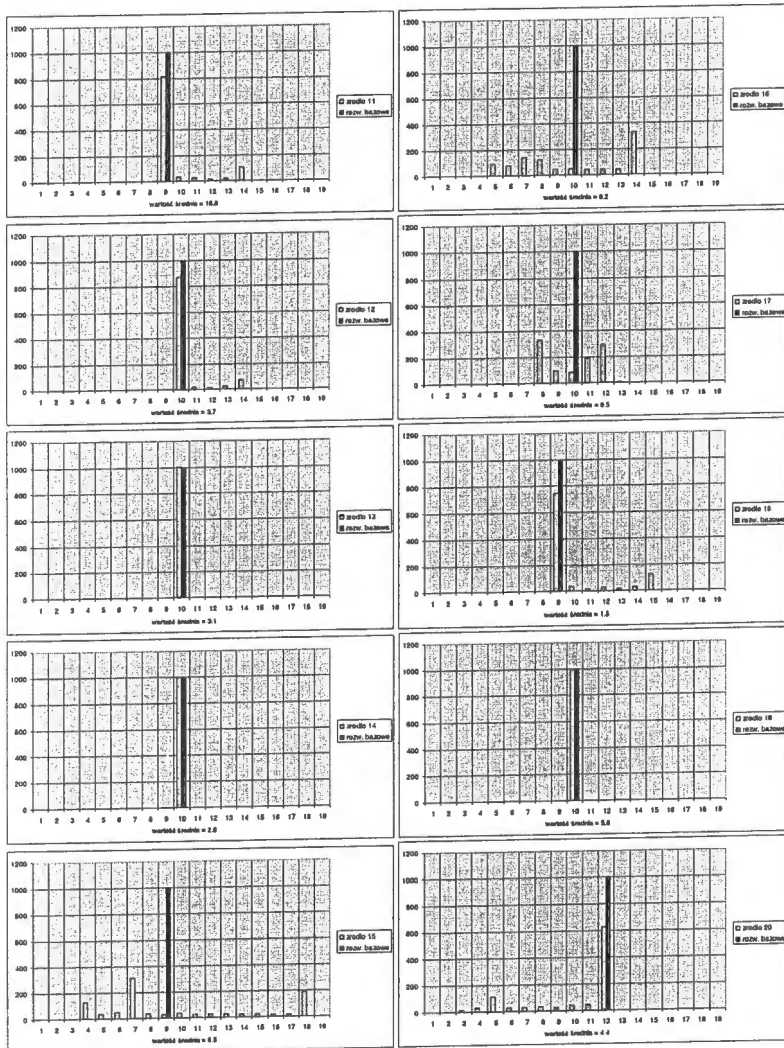
1) 0.0 - 0.15	6) 0.56 - 0.65	11) 1.06 - 1.15	16) 1.56 - 1.65
2) 0.16 - 0.25	7) 0.66 - 0.75	12) 1.16 - 1.25	17) 1.66 - 1.75
3) 0.26 - 0.35	8) 0.76 - 0.85	13) 1.26 - 1.35	18) 1.76 - 1.85
4) 0.36 - 0.45	9) 0.86 - 0.95	14) 1.36 - 1.45	19) 1.86 - 1.95
5) 0.46 - 0.55	10) 0.96 - 1.05	15) 1.46 - 1.55	

Rys 9b. Histogram emisji źródeł 11-20 dla rozwiązania optymalnego ($J_p = 2.63 \cdot 10^6$)



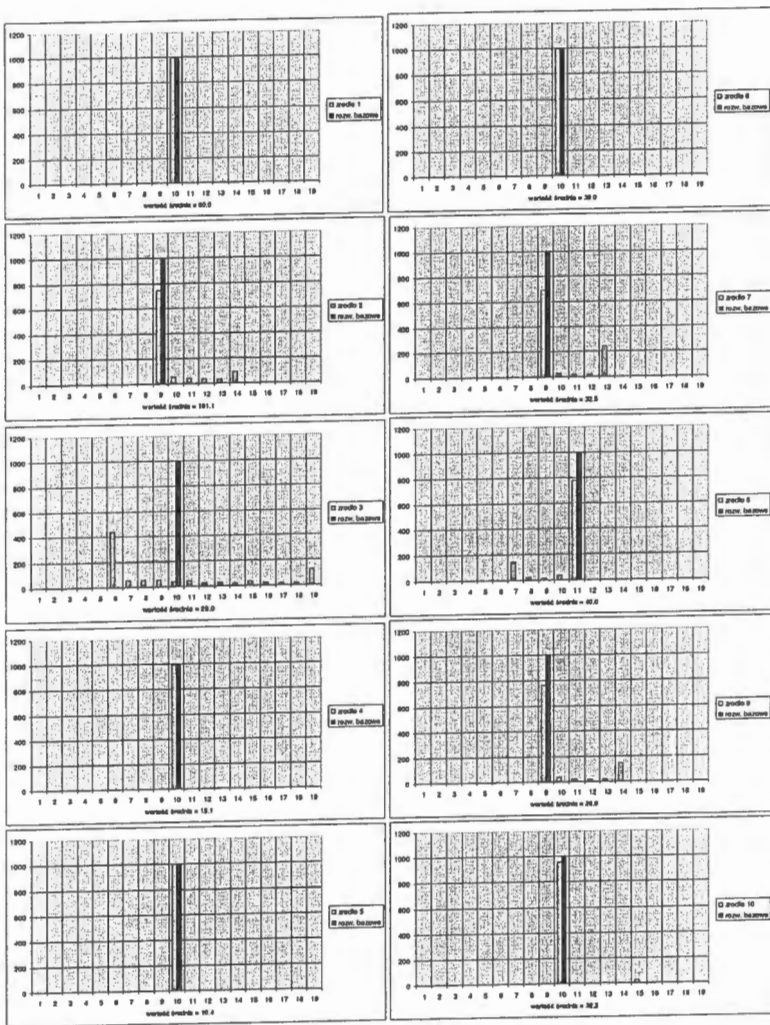
- Kategorie:
- | | | | |
|----------------|-----------------|-----------------|-----------------|
| 1) 0.0 - 0.15 | 6) 0.55 - 0.65 | 11) 1.05 - 1.15 | 16) 1.55 - 1.65 |
| 2) 0.15 - 0.25 | 7) 0.65 - 0.75 | 12) 1.15 - 1.25 | 17) 1.65 - 1.75 |
| 3) 0.25 - 0.35 | 8) 0.75 - 0.85 | 13) 1.25 - 1.35 | 18) 1.75 - 1.85 |
| 4) 0.35 - 0.45 | 9) 0.85 - 0.95 | 14) 1.35 - 1.45 | 19) 1.85 - 1.95 |
| 5) 0.45 - 0.55 | 10) 0.95 - 1.05 | 15) 1.45 - 1.55 | |

Rys. 10a. Histogram emisji źródeł 1-10 dla rozwiązania optymalnego ($J_p = 3.24 \cdot 10^6$)



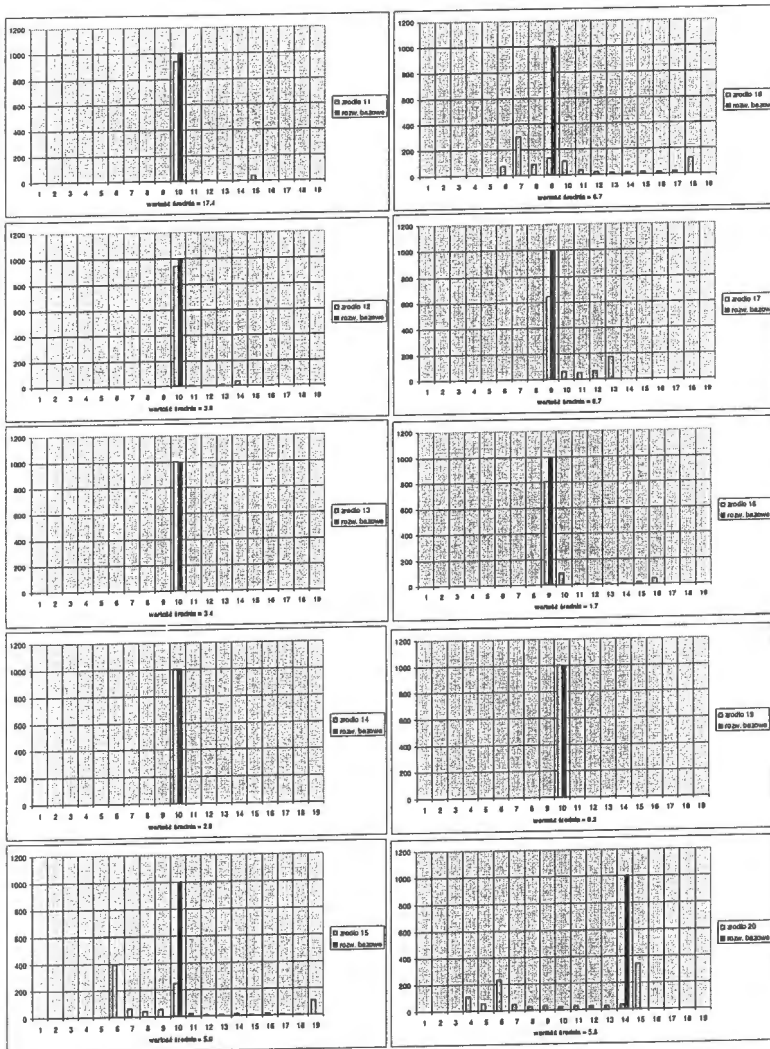
- Kategorie:
- | | | | |
|----------------|-----------------|-----------------|-----------------|
| 1) 0.0 - 0.15 | 6) 0.55 - 0.65 | 11) 1.05 - 1.15 | 16) 1.55 - 1.65 |
| 2) 0.15 - 0.25 | 7) 0.65 - 0.75 | 12) 1.15 - 1.25 | 17) 1.65 - 1.75 |
| 3) 0.25 - 0.35 | 8) 0.75 - 0.85 | 13) 1.25 - 1.35 | 18) 1.75 - 1.85 |
| 4) 0.35 - 0.45 | 9) 0.85 - 0.95 | 14) 1.35 - 1.45 | 19) 1.85 - 1.95 |
| 5) 0.45 - 0.55 | 10) 0.95 - 1.05 | 15) 1.45 - 1.55 | |

Rys. 10b. Histogram emisji źródeł 11-20 dla rozwiązania optymalnego ($J_p = 3.24 \cdot 10^6$)



- Kategorie:
- | | | | |
|----------------|-----------------|-----------------|-----------------|
| 1) 0.0 - 0.15 | 6) 0.55 - 0.65 | 11) 1.05 - 1.15 | 16) 1.55 - 1.65 |
| 2) 0.15 - 0.25 | 7) 0.65 - 0.75 | 12) 1.15 - 1.25 | 17) 1.65 - 1.75 |
| 3) 0.25 - 0.35 | 8) 0.75 - 0.85 | 13) 1.25 - 1.35 | 18) 1.75 - 1.85 |
| 4) 0.35 - 0.45 | 9) 0.85 - 0.95 | 14) 1.35 - 1.45 | 19) 1.85 - 1.95 |
| 5) 0.45 - 0.55 | 10) 0.95 - 1.05 | 15) 1.45 - 1.55 | |

Rys. 11a. Histogram emisji źródeł 1-10 dla rozwiązania optymalnego ($J_p = 3.92 \cdot 10^6$)



- Kategorie:
- | | | | |
|----------------|-----------------|-----------------|-----------------|
| 1) 0.0 - 0.15 | 6) 0.55 - 0.65 | 11) 1.05 - 1.15 | 16) 1.55 - 1.65 |
| 2) 0.15 - 0.25 | 7) 0.65 - 0.75 | 12) 1.15 - 1.25 | 17) 1.65 - 1.75 |
| 3) 0.25 - 0.35 | 8) 0.75 - 0.85 | 13) 1.25 - 1.35 | 18) 1.75 - 1.85 |
| 4) 0.35 - 0.45 | 9) 0.85 - 0.95 | 14) 1.35 - 1.45 | 19) 1.85 - 1.95 |
| 5) 0.45 - 0.55 | 10) 0.95 - 1.05 | 15) 1.45 - 1.55 | |

Rys. 11b. Histogram emisji źródeł 11-20 dla rozwiązania optymalnego ($J_p = 3.92 \cdot 10^6$)

Tablica 4. Porównanie rozwiązań optymalnych dla $J_p = 2.6310^6$ oraz $J_o = 1.910^5$; koszt całkowity $C_o \approx 172$

a) rozwiązanie z uwzględnieniem niepewności

1	0.00	0.00	0.00	0.00	0.00	0.00	1.00	0.00
2	0.66	0.00	0.34	0.00	0.00	0.00	0.00	0.00
3	0.00	0.00	0.00	1.00	0.00	0.00	0.00	0.00
4	0.00	0.00	0.00	0.08	0.00	0.00	0.92	0.00
5	0.00	0.00	0.00	0.00	0.00	0.00	0.00	1.00
6	0.00	0.00	0.00	1.00	0.00	0.00	0.00	0.00
7	0.00	0.87	0.00	0.13	0.00	0.00	0.00	0.00
8	0.00	1.00	0.00	0.00	0.00	0.00	0.00	0.00
9	0.00	0.76	0.00	0.24	0.00	0.00	0.00	0.00
10	0.34	0.00	0.66	0.00	0.00	0.00	0.00	0.00
11	0.00	0.35	0.00	0.65	0.00	0.00	0.00	0.00
12	0.00	0.00	0.00	0.00	0.00	0.00	0.24	0.76
13	0.00	0.00	0.00	0.00	0.00	0.00	0.00	1.00
14	0.00	0.00	0.00	0.00	0.00	0.00	0.00	1.00
15	0.00	0.00	0.00	0.63	0.00	0.34	0.00	0.03
16	0.00	0.00	0.00	0.80	0.18	0.02	0.00	0.00
17	0.02	0.11	0.71	0.16	0.00	0.00	0.00	0.00
18	0.00	0.00	0.00	0.00	0.00	0.42	0.00	0.58
19	0.00	0.00	0.00	1.00	0.00	0.00	0.00	0.00
20	0.00	0.00	0.00	1.00	0.00	0.00	0.00	0.00

$$J_o/J_p = 0.0727$$

$$C_o = 170.7$$

b) rozwiązanie bazowe (ZA - sformułowanie ciągłe)

0.00	0.00	0.00	0.00	0.00	0.00	0.00	1.00	0.00
0.92	0.00	0.08	0.00	0.00	0.00	0.00	0.00	0.00
0.00	0.00	0.00	1.00	0.00	0.00	0.00	0.00	0.00
0.00	0.00	0.00	0.00	0.00	0.00	0.00	1.00	0.00
0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	1.00
0.00	0.00	0.00	1.00	0.00	0.00	0.00	0.00	0.00
0.00	1.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
0.00	1.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
0.00	1.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
0.00	0.00	1.00	0.00	0.00	0.00	0.00	0.00	0.00
0.00	0.00	0.00	1.00	0.00	0.00	0.00	0.00	0.00
0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	1.00
0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	1.00
0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	1.00
0.00	0.00	0.00	0.29	0.00	0.71	0.00	0.00	0.00
0.00	0.00	0.00	0.92	0.08	0.00	0.00	0.00	0.00
0.00	0.03	0.93	0.04	0.00	0.00	0.00	0.00	0.00
0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	1.00
0.00	0.02	0.00	1.00	0.00	0.00	0.00	0.00	0.00
0.00	0.00	0.00	1.00	0.00	0.00	0.00	0.00	0.00

$$J_o/J_p = 0.0724$$

$$C_o = 171.9$$

Tablica 5. Porównanie rozwiązań optymalnych dla $J_p = 3.2410^6$ oraz $J_o = 1.910^5$; koszt całkowity $C_0 \approx 191$

a) rozwiązanie z uwzględnieniem niepewności

1	0.00	0.00	0.00	0.00	0.00	0.00	1.00	0.00
2	0.36	0.00	0.64	0.00	0.00	0.00	0.00	0.00
3	0.00	0.00	0.00	0.70	0.00	0.00	0.30	0.00
4	0.00	0.00	0.00	0.00	0.00	0.00	1.00	0.00
5	0.00	0.00	0.00	0.00	0.00	0.00	0.00	1.00
6	0.00	0.00	0.00	1.00	0.00	0.00	0.00	0.00
7	0.00	0.55	0.00	0.45	0.00	0.00	0.00	0.00
8	0.00	1.00	0.00	0.00	0.00	0.00	0.00	0.00
9	0.00	0.44	0.00	0.56	0.00	0.00	0.00	0.00
10	0.12	0.00	0.88	0.00	0.00	0.00	0.00	0.00
11	0.00	0.13	0.00	0.87	0.00	0.00	0.00	0.00
12	0.00	0.00	0.00	0.00	0.00	0.00	0.11	0.89
13	0.00	0.00	0.00	0.00	0.00	0.00	0.00	1.00
14	0.00	0.00	0.00	0.00	0.00	0.00	0.00	1.00
15	0.00	0.00	0.00	0.31	0.00	0.51	0.00	0.18
16	0.00	0.00	0.00	0.46	0.36	0.18	0.00	0.00
17	0.00	0.04	0.50	0.46	0.00	0.00	0.00	0.00
18	0.00	0.00	0.00	0.00	0.00	0.20	0.00	0.80
19	0.00	0.00	0.00	1.00	0.00	0.00	0.00	0.00
20	0.00	0.00	0.00	0.74	0.00	0.23	0.00	0.03

$J_o/J_p = 0.0590$

$C_0 = 189.9$

b) rozwiązanie bazowe (ZA - sformułowanie ciągłe)

0.00	0.00	0.00	0.00	0.00	0.00	0.00	1.00	0.00
0.00	0.00	1.00	0.00	0.00	0.00	0.00	0.00	0.00
0.00	0.00	0.00	1.00	0.00	0.00	0.00	0.00	0.00
0.00	0.00	0.00	0.00	0.00	0.00	0.00	1.00	0.00
0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	1.00
0.00	1.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
0.00	1.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
0.00	0.04	0.00	0.96	0.00	0.00	0.00	0.00	0.00
0.00	0.00	1.00	0.00	0.00	0.00	0.00	0.00	0.00
0.00	0.00	0.00	1.00	0.00	0.00	0.00	0.00	0.00
0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	1.00
0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	1.00
0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	1.00
0.00	0.00	0.00	0.15	0.00	0.85	0.00	0.00	0.00
0.00	0.00	0.00	0.39	0.61	0.01	0.00	0.00	0.00
0.00	0.01	0.58	0.41	0.00	0.00	0.00	0.00	0.00
0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	1.00
0.00	0.00	0.00	1.00	0.00	0.00	0.00	0.00	0.00
0.00	0.00	0.00	1.00	0.00	0.00	0.00	0.00	0.00

$J_o/J_p = 0.0586$

$C_0 = 191.6$

Tablica 6. Porównanie rozwiązań optymalnych dla $J_p = 3.9210^6$ oraz $J_o = 1.910^5$; koszt całkowity $C_o \approx 208$

a) rozwiązanie z uwzględnieniem niepewności

1	0.00	0.00	0.00	0.00	0.00	0.00	1.00	0.00
2	0.16	0.00	0.84	0.00	0.00	0.00	0.00	0.00
3	0.00	0.00	0.00	0.31	0.00	0.00	0.69	0.00
4	0.00	0.00	0.00	0.00	0.00	0.00	1.00	0.00
5	0.00	0.00	0.00	0.00	0.00	0.00	0.00	1.00
6	0.00	0.00	0.00	1.00	0.00	0.00	0.00	0.00
7	0.00	0.27	0.00	0.73	0.00	0.00	0.00	0.00
8	0.00	0.83	0.00	0.17	0.00	0.00	0.00	0.00
9	0.00	0.18	0.00	0.82	0.00	0.00	0.00	0.00
10	0.00	0.00	1.00	0.00	0.00	0.00	0.00	0.00
11	0.00	0.00	0.00	1.00	0.00	0.00	0.00	0.00
12	0.00	0.00	0.00	0.00	0.00	0.00	0.00	1.00
13	0.00	0.00	0.00	0.00	0.00	0.00	0.00	1.00
14	0.00	0.00	0.00	0.00	0.00	0.00	0.00	1.00
15	0.00	0.00	0.00	0.12	0.00	0.40	0.00	0.48
16	0.00	0.00	0.00	0.21	0.34	0.38	0.07	0.00
17	0.00	0.02	0.26	0.72	0.00	0.00	0.00	0.00
18	0.00	0.00	0.00	0.00	0.00	0.08	0.00	0.92
19	0.00	0.00	0.00	1.00	0.00	0.00	0.00	0.00
20	0.00	0.00	0.00	0.46	0.00	0.42	0.00	0.13

$J_o/J_p = 0.0487$

$C_o = 207.5$

b) rozwiązanie bazowe (ZA - sformułowanie ciągłe)

0.00	0.00	0.00	0.00	0.00	0.00	1.00	0.00
0.00	0.00	1.00	0.00	0.00	0.00	0.00	0.00
0.00	0.00	0.00	0.31	0.00	0.00	0.69	0.00
0.00	0.00	0.00	0.00	0.00	0.00	1.00	0.00
0.00	0.00	0.00	0.00	0.00	0.00	0.00	1.00
0.00	0.00	0.00	1.00	0.00	0.00	0.00	0.00
0.00	0.00	0.00	1.00	0.00	0.00	0.00	0.00
0.00	1.00	0.00	0.00	0.00	0.00	0.00	0.00
0.00	0.00	0.00	1.00	0.00	0.00	0.00	0.00
0.00	0.00	1.00	0.00	0.00	0.00	0.00	0.00
0.00	0.00	0.00	1.00	0.00	0.00	0.00	0.00
0.00	0.00	0.00	0.00	0.00	0.00	0.00	1.00
0.00	0.00	0.00	0.00	0.00	0.00	0.00	1.00
0.00	0.00	0.00	0.00	0.00	0.00	0.00	1.00
0.00	0.00	0.00	0.00	0.00	0.00	0.00	1.00
0.00	0.00	0.00	0.00	0.00	0.00	0.99	0.01
0.00	0.00	0.00	0.00	0.96	0.10	0.00	0.00
0.00	0.00	0.07	0.92	0.00	0.00	0.00	0.00
0.00	0.00	0.00	0.00	0.00	0.00	0.00	1.00
0.00	0.00	0.00	1.00	0.00	0.00	0.00	0.00
0.00	0.00	0.00	1.00	0.00	0.00	0.00	0.00

$J_o/J_p = 0.0484$

$C_o = 208.7$

Algorytm optymalizacyjny zastosowany do obliczania wartości funkcji celu, w kolejnych iteracjach wykorzystuje rozkłady stężeń odpowiadające poszczególnym źródłom emisji, które następnie są sumowane. Udział każdego ze źródeł, zgodnie z zależnościami (3) oraz (4), wynika z wartości jednostkowych zawartych w macierzy przeniesienia $A(x, y)$ oraz aktualnej wielkości emisji źródła, u_i . W celu uwzględnienia wpływu niepewności na rozwiązanie zadania (ZA), ustalono zakres i rozkład niepewności emisji u_i dla wszystkich badanych źródeł i dla takiego zakresu niepewności rozwiązywano zadanie optymalizacyjne. Aby uwzględnić wpływ wszystkich elementów stanowiących potencjalne źródła niepewności (intensywność emisji, parametry techniczne źródeł, dane meteorologiczne z uwzględnieniem stanu równowagi atmosfery), przyjęto średni zakres niepewności wynikający z analizy przedstawionej w rozdziale 4. Uwzględniając uwagi zamieszczone na końcu tego rozdziału (przeszacowany wpływ stanu równowagi atmosfery w niektórych receptorach), dla opisu niepewności emisji u_i w analizowanych źródłach przyjęto ostatecznie rozkład normalny, zakres około $\pm 47\%$.

6. Wnioski

Przeprowadzone obliczenia miały na celu oszacowanie niepewności przy rozwiązywaniu zadania optymalizacyjnego (ZA), gdzie przy ustalonej wartości początkowej wskaźnika jakości, J_p należy osiągnąć jego założoną wartość końcową, J_o , przy minimalnych kosztach.

Obliczenia przeprowadzono dla trzech wartości początkowych wskaźnika: a) $J_p = 2.6310^6$, b) $J_p = 3.2410^6$, c) $J_p = 3.9210^6$ (odpowiadały one trzem poziomom nominalnych wartości emisji źródeł), natomiast końcowa wartość wskaźnika we wszystkich trzech przypadkach wynosiła $J_o = 1.910^5$. Dla każdej z wartości początkowych wykonano 1000 przebiegów algorytmu optymalizacyjnego, przy czym wejściowe dane emisyjne wprowadzane były zgodnie z przyjętym rozkładem. Uzyskane wyniki były porównywane z bazowym rozwiązaniem zadania optymalizacyjnego (tzw. algorytm „ciągły”, opisany w [5]), otrzymanym dla nominalnych i ustalonych wartości emisji źródeł, które dla trzech rozważanych przypadków (odniesiony do wartości podanych w tablicy 2 dla sezonu zimowego) wynosiły odpowiednio: a) $0.9 * u_i$, b) $1.0 * u_i$, c) $1.1 * u_i$.

Wyniki przedstawione na rysunkach 9, 10 oraz 11 odpowiadają trzem omawianym przypadkom. Dla każdego z 20 analizowanych źródeł przedstawiają one porównanie końcowej (optymalnej) wartości emisji rozwiązania bazowego zadania (ZA) z rozkładem analogicznych emisji końcowych wynikających z realizacji algorytmu Monte Carlo. Rozkład ten jest przedstawiony w postaci histogramu 19 kategorii rozmieszczonych symetrycznie wokół wartości średniej. Jest możliwość porównania z rozwiązaniem bazowym zarówno otrzymanej wartości średniej, jak i szerokości oraz charakteru rozkładu. Składa się to w konsekwencji na ocenę zakresu niepewności rozwiązania.

W każdym z trzech analizowanych przypadków można wskazać ok. 10-ciu źródeł, dla których otrzymane rozwiązanie pokrywa się dokładnie (lub prawie dokładnie) z rozwiązaniem bazowym. Z kolei można wskazać, w których emitatorach występuje bardziej znaczący rozkład niepewności końcowej wartości emisji (rozwiązania optymalnego) wokół wartości średniej. Na

ogół, tego typu „niepewne” rozwiązanie charakteryzuje te same źródła (emitory nr: 2,3, 15,16,17,20), niezależnie od początkowej wartości emisji. Są to np. źródła położone w pobliżu brzegu obszaru lub też źródła o małej (pomijalnej) wartości emisji nominalnej, w porównaniu z dominującym źródłem nr 1.

Druga część prezentowanych wyników zawiera porównania, dla trzech analizowanych zestawów obliczeń, rozwiązań optymalnych dotyczących przydziału technologii odsiarczania spalin do poszczególnych źródeł emisji. Jak wspomniano wcześniej, w obliczeniach których celem była ocena niepewności rozwiązań, zastosowano tzw. „ciągle” sformułowanie zadania optymalizacyjnego i odpowiedni algorytm obliczeniowy [5,6]. Pozwala to lepiej (bardziej bezpośrednio) porównywać wyniki, bowiem rozwiązania uwzględniające niepewność danych będą miały z natury charakter rozmyty. Odpowiednie porównania wyników dotyczących optymalnego przydziału technologii, dla trzech analizowanych scenariuszy emisyjnych, zawierają tablice 4 – 6.

Odpowiednia para tablic umożliwia porównanie optymalnego przydziału technologii dla rozwiązania bazowego z rozwiązaniem, w którym uwzględniono niepewność danych wejściowych. Niewielkie „rozmycie” wyników w rozwiązaniu bazowym jest efektem wykorzystania sformułowania ciągłego samego zadania optymalizacji. Z kolei, znacznie większe „rozmycie” drugiego rozwiązania w każdej parze jest odbiciem niepewności danych wprowadzanych na wejściu. Tablice 4–6 odpowiadają kolejno rosnącym wartościom początkowym wskaźnika jakości, więc w rozwiązaniu optymalnym, zarówno względna poprawa tego wskaźnika jak i koszt całkowity są większe (przy czym odpowiednie wartości dla rozwiązania z niepewnością oraz bazowego są bardzo bliskie).

W każdym z uzyskanych rozwiązań optymalnych jest 8–10 źródeł, w których przyporządkowanie technologii ma charakter całkowitoliczbowy (pokrywający się z rozwiązaniem bazowym), natomiast pozostałe przyporządkowania mają charakter rozmyty, co bezpośrednio wynika z uwzględnionej niepewności. Porównując z kolei tę ostatnią kategorię z rozwiązaniem bazowym widać, że maksymalna wartość w rozwiązaniu rozmytym pokrywa się z reguły z pozycją „1” w rozwiązaniu bazowym. Wynika stąd, że rozwiązania optymalne uwzględniające niepewność, pomimo rozmytego kształtu, poprawnie charakteryzują poszukiwane rozwiązanie optymalne.

Podsumowując uzyskane wyniki można stwierdzić, że w zadaniach optymalizacyjnych wykorzystujących prognozy modeli transportu zanieczyszczeń, ze względu na zawartą w tych prognozach niepewność, niecelowe wydaje się stosowanie dokładnych i czasochłonnych algorytmów obliczeniowych. Z punktu widzenia zastosowań praktycznych, wystarczające będzie zastosowanie prostszych metod, np. heurystycznych. Z drugiej strony, otrzymane wyniki obliczeń pozwalają sformułować opinię, że pomimo niepewności zawartej w rozwiązaniach zadania optymalizacyjnego, jego wyniki są wystarczająco dokładne dla celów praktycznych i mogą być z pożytkiem wykorzystywane we wspomaganiu strategicznych decyzji w dziedzinie kontroli i zarządzania jakością środowiska.

Literatura

- [1] ApSimon H.M., Warren R.F., Kayin S.: *Addressing uncertainty in environmental modeling: a case study of integrated assessment of strategies to combat long-range transboundary air pollution*. Atmospheric Environment, 36, 2002, 5417 – 5426.
- [2] Durbach I.N., Stewart T.J.: *Using expected values to simplify decision making under uncertainty*. Omega - the International Journal of Management Science. 37. 2009, 312 – 330.
- [3] Hanna S.R., Chang J.C., Fernau M.E.: *Monte Carlo estimates of uncertainties in predictions by photochemical grid model (UAM-IV) due to uncertainties in input variables*. Atmospheric Environment. 32, 1998, 3619 – 3628.
- [4] Hanna S.R., Lu Z., Frey H.C., Wheeler N., Vukovich J., Arunachalam S., Fernau M., Hansen D.A.: *Uncertainties in predicted ozone concentrations due to input uncertainties for the UAM-V photochemical grid model applied to the July 1995 OTAG domain*. Atmospheric Environment. 35, 2001, 891 – 903.
- [5] Holnicki P.: *Modele propagacji zanieczyszczeń atmosferycznych w zastosowaniu do kontroli i sterowania jakością środowiska*. Akademska Oficyna Wydawnicza EXIT, Seria: Badania Systemowe, tom 46, (211 str.). Warszawa 2006.
- [6] Holnicki P.: *Wpływ danych wejściowych na niepewność prognoz w modelowaniu zanieczyszczeń atmosfery*. Raport badawczy RB/44/2009, IBS PAN, 2009, 31 pp.
- [7] Markiewicz M.: *Podstawy modelowania rozprzestrzeniania się zanieczyszczeń w powietrzu atmosferycznym*. Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa (2004).
- [8] Page T., Whyatt J.D., Beven K.J., Metcalfe S.E.: *Uncertainty in modeled estimates of acid deposition across Wales: a GLUE approach*. Atmospheric Environment, 38, 2003, 2079 – 2090.
- [9] Park S.-K., Cobb C.E., Wade K., Mulholland J., Hu Y., Russel A.G.: *Uncertainty in air quality model evaluation for particulate matter due to spatial variations in pollutant concentrations*. Atmospheric Environment, 40, 2006, S563 – S573.
- [10] Russel A., Dennis D.: *NASTRO critical review of photochemical models and modeling*. Atmospheric Environment, 34, 2000, 2283 – 2324.
- [11] Sax T., Isakov V.: *A case study for assessing uncertainty in local-scale regulatory air quality modeling applications*. Atmospheric Environment, 37, 2003, 3481—3489.
- [12] Sportisse B.: *A review of current issues in air pollution modeling and simulation*. Computational Geosciences, 11, 2007, 159 – 181.
- [13] Warren R.F., ApSimon H.M.: *Uncertainties in integrated assessment modeling of abatement strategies: illustrations with the SAM model*. Environment Science and Policy, 2, 1999, 439 – 456.
- [14] Zimmermann H.-J.: *An application-oriented view of modeling uncertainty*. European Journal of Operational Research, 122, 1999, 190-198.
- [15] *Rozporządzenie Ministra Środowiska z dnia 3 marca 2008 r. w sprawie poziomów niektórych substancji w powietrzu*. Dziennik Ustaw Nr 47, poz. 281.

UNCERTAINTY IN AIR QUALITY MANAGEMENT SYSTEMS

Abstract

Computer models of air pollution transport are more and more widely used as decision support tools in environmental quality protection. An important application of air pollution models is to support decisions concerning air quality management and emission control. To quantify possible ecological or health benefits of emission abatement, there is a need to estimate the incremental contribution of the respective group of emission sources to ambient concentrations with the reasonable accuracy. However, due to significant complexity of such forecasting systems, there exist many sources of imprecision or uncertainty in the modeling process. This paper addresses the problem of uncertainty of emission inventory and meteorological data as well as impact of these uncertainties on the predicted air pollution concentrations. Recently one can also observe a substantial progress in construction and applications of the integrated assessment models and decision support systems. Such a system integrates air pollution transport model with some additional ecological, economic or technological standards and constraints. Application of the optimization methods makes it possible to formulate and solve problems of the optimal strategy of emission reduction. However, uncertainty of the forecasting model constitutes the significant source of uncertainty of decision support system. In the paper the overall uncertainty of environment-oriented decision support systems is considered. The analysis is applied for the integrated assessment model applied for regional-scale optimization problem of sulfur oxides emission abatement.

Keywords: *air pollution dispersion model, integrated assessment system, uncertainty analysis.*



