

50/2009

Raport Badawczy
Research Report

RB/44/2009

**Wpływ danych wejściowych
na niepewność prognoz
w modelowaniu
zanieczyszczeń atmosfery**

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 2009

WPLYW DANYCH WEJŚCIOWYCH NA NIEPEWNOŚĆ PROGNOZ W MODELOWANIU ZANIECZYSZCZEŃ ATMOSFERY

Piotr Holnicki

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

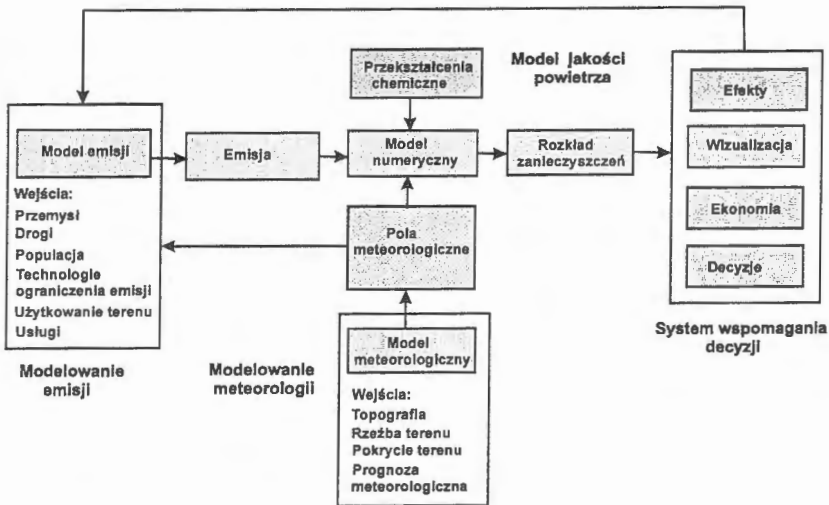
Modele propagacji zanieczyszczeń atmosferycznych są coraz powszechniej stosowane do wspomagania decyzji w dziedzinie kontroli jakości środowiska naturalnego. Rozwijane w ostatnich latach zintegrowane systemy oceny jakości środowiska, uwzględniają – poza wielkością emisji oraz danymi meteorologicznymi – pewne dodatkowe warunki i ograniczenia, np. typu ekonomicznego lub technologicznego. System taki, wykorzystując prognozy propagacji zanieczyszczeń, ma umożliwiać analizę różnych scenariuszy rozwoju (pod kątem ich efektów ekologicznych), może też stanowić narzędzie wspomagające podejmowanie decyzji. Wykorzystanie metod optymalizacyjnych daje ponadto możliwość wyznaczania najkorzystniejszej w danych warunkach strategii. Sama struktura modelu prognostycznego, jak i obszary głównych danych wejściowych (emisyjne, meteorologiczne, topograficzne, fizjograficzne), stanowią bardzo istotne źródło potencjalnej niepewności generowanych prognoz. W pracy omówiono podstawowe źródła tej niepewności oraz metody jej szacowania. Wykonane obliczenia testowe oparto na wykorzystaniu algorytmu Monte Carlo..

Słowa kluczowe: zanieczyszczenia atmosferyczne, model transportu zanieczyszczeń, analiza niepewność prognoz, system zintegrowany.

1. Wstęp

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 [1,8,10,15,18] (w tym dla zdrowia ludzkiego) oraz do wyboru właściwej (optymalnej) strategii przeciwdziałania, np. przez ograniczenie poziomu emisji lub przejście na inną technologię wytwarzania energii.

System wspomagania decyzji, którego ogólny schemat blokowy przedstawiono na rys. 1, jest dość złożony, dlatego 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, emisyjne, fizjograficzne).



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 warunków (zakresów) parametrów modelu oraz danych wejściowych gwarantujących poprawne działanie modelu, (d) określenia warunków, w których prognozy modelu można traktować jako najlepsze,


W większości prac poświęconych temu zagadnieniu uważa się, że głównym źródłem niepewności zawartej w prognozach modelu są dane wejściowe (meteorologia oraz emisja) a nie sam model. 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 „nie obserwowalne” (niemierzalne lub trudne do zmierzenia) w praktyce [2,9,15,18]. 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.

Najczęściej stosowanymi metodami analizy wrażliwości/niepewności prognoz modeli zanieczyszczeń [2,5,14,16,18] są: analiza oparta na wykorzystaniu tzw. „małych zaburzeń” lub analiza typu „brute-force” z wykorzystaniem algorytmu Monte-Carlo [3,5,11,15,19].

2. Źródła niepewności prognoz wynikające konstrukcji modelu

2.1 Opis matematyczny procesów transportu zanieczyszczeń

Obecnie istnieje i jest stosowanych wiele rodzajów modeli prognostycznych, dostosowanych odpowiednio do skali miejskiej lub regionalnej [7,10,15,18]. Pomimo dużej ich różnorodności, większość tych realizacji ma pewne cechy wspólne. W szczególności, uwzględniają one podstawowe procesy mające wpływ na transport zanieczyszczeń przedstawione schematycznie na rys. 2.



Rys. 2. Najważniejsze procesy w transporcie zanieczyszczeń [10].

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

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

(1)


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

gdzie 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/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 na jednym z dwóch podstawowych rozwiązań: lagranżowskim lub eulerowskim (rys. 3). 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.

W modelach eulerowskich wykorzystana jest skończenie-wymiarowa aproksymacja równań transportu (1), oparta na pełnej dyskretyzacji przestrzennej analizowanego obszaru, zarówno horyzontalnej, jak i pionowej (porównaj rys. 2). Przyjęty krok dyskretyzacji przestrzennej, wysokość warstwy mieszania oraz liczba warstw (liczonych w pionie) modelu zależy od skali przestrzennej obszaru oraz zakładanej dokładności prognoz. Z drugiej strony, parametry te wpływają bezpośrednio na wymagania sprzętowe oraz czas obliczeń, dlatego przyjęte wartości są wynikiem kompromisu pomiędzy oczekiwaną dokładnością wyników a wydajnością obliczeniową.




Model lagranżowski

$$x'_i(t_0 + \Delta t) = x_i(t_0) + v(x_i, t_0) \Delta t$$

$$x_i(t_0 + \Delta t) = x_i(t_0) + 0,5 \cdot [v(x_i, t_0) + v(x'_i, t_0 + \Delta t)] \Delta t$$

$$\frac{dc}{dt} = [\text{dyfuzja}] + [\text{emisja}] + [\text{depozycja/przemiany}]$$



Model eulerowski


$$\frac{\partial c}{\partial t} = [\text{adwekcja}] + [\text{dyfuzja}] + [\text{emisja}] + [\text{depozycja/przemiany}]$$

<http://www.arl.noaa.gov/slides>

Rys. 3. Zasada funkcjonowania modelu lagranżowskiego i eulerowskiego

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/RAAINS [2]), jest możliwość niezależnej analizy poszczególnych źródeł emisji i tworzenia jednostkowych macierzy przeniesienia źródło – receptor, które są wykorzystywane m.in. w analizie scenariuszy ograniczania emisji.



Rys. 4. Schemat dyskretyzacji obszaru w modelu eulerowskim [15]

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 (patrz np. model EMEP/RAAINS), jest możliwość niezależnej analizy poszczególnych źródeł emisji i tworzenia jednostkowych macierzy przeniesienia źródło – receptor, które są wykorzystywane m.in. w analizie scenariuszy ograniczania emisji.

Z drugiej strony uważa się [1,15,18], chociaż nie prowadzono dotychczas dokładnych studiów na ten temat, że w rozwiązaniach lagranżowskich jest kilka dość istotnych, potencjalnych źródeł niepewności prognoz. Po pierwsze, rzeczywiste trajektorie przemieszczania się zanieczyszczeń związane z lokalizacją danego źródła różnią się znacznie w zależności od wysokości, na której są rozpatrywane, natomiast w modelach tego typu pionowy profil pola wiatru uwzględniany jest, co najwyżej w dużym uproszczeniu. W przypadku prognozy krótkoterminowej (np. kilkudniowej) efekt ten może powodować istotne błędy. Innym źródłem niepewności jest pomijanie w takich rozwiązaniach (lub uwzględnianie w dużym uproszczeniu) procesów dyfuzji turbulencyjnej, które mają istotny wpływ na proces rozprzestrzeniania się zanieczyszczeń.

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.

2.2 Implementacja numeryczna modelu

W schemacie numerycznym stosowanym do rozwiązywania układu równań transportu (1) przeważnie wykorzystuje się rozszczepienie poszczególnych równań względem głównych procesów: transportu, dyfuzji, przemian chemicznych, a także względem zmiennych przestrzennych (oddzielnie analizowany jest transport horyzontalny i pionowy). Przedstawiony poniżej układ równań różniczkowych (2) stanowi przykład rozdzielania wyjściowego układu równań transportu zanieczyszczeń względem poszczególnych operatorów: adwekcji, dyfuzji oraz przemian chemicznych.

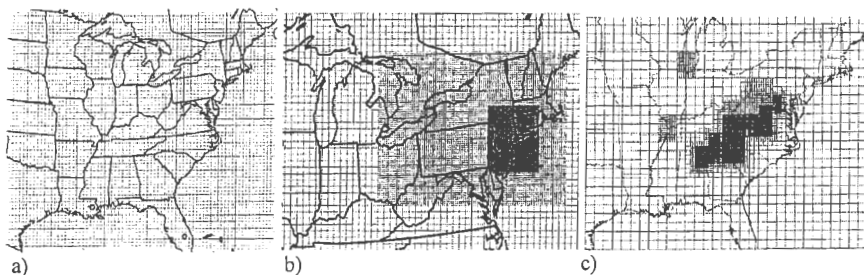
Algorytm numeryczny wykorzystuje skończenie-wymiarową aproksymację układu równań transportu zanieczyszczeń, przy dyskretyzacji horyzontalnej oraz pionowej dostosowanej do wielkości obszaru obliczeniowego. Jednym ze źródeł niepewności w tym rozwiązaniu są czysto numeryczne efekty: (a) dyfuzji numerycznej (powodującej spłaszczenie dużych wartości stężeń, tzw. „pików”), (b) pojawiania się nie fizycznych przeregulowań lub oscylacji, zwłaszcza w obszarach o dużych wartościach gradientu stężenia. Niwelowanie tych efektów wymaga użycia odpowiednio skonstruowanych schematów numerycznych i stosowania dostatecznie małych wartości kroku dyskretyzacji przestrzennej i czasowej (tzw. *shape preserving approximation*) [7,15], co z kolei wpływa na zmniejszenie wydajności obliczeniowej modelu.

$$\begin{aligned} \left. \frac{\partial c}{\partial t} \right|_H &= \nabla \cdot \vec{U}c + \nabla K \rho \nabla \left(\frac{c}{\rho} \right) = L_H(c), \\ \left. \frac{\partial c}{\partial t} \right|_V &= \frac{\partial wc}{\partial z} + \frac{\partial}{\partial z} \rho K \frac{\partial (c/\rho)}{\partial z} = L_V(c), \\ \left. \frac{\partial c}{\partial t} \right|_S &= [R(c,t) + S] = L_S(c), \\ \left. \frac{\partial c_i}{\partial t} \right|_{Total} &= (L_H + L_V + L_S)(c). \end{aligned} \tag{2}$$

Krok dyskretyzacji przestrzennej oraz liczba warstw modelu są dostosowane do wielkości modelowanego obszaru oraz przyjętej wysokości warstwy mieszania i mają bezpośredni wpływ na dokładność obliczeń. W przypadku modeli skali miejskiej krok dyskretyzacji horyzontalnej wynosi najczęściej od 1 km do 5 km, natomiast w modelach regionalnych od 10 km do 200 km (np. 150 km w modelu EMEP). Dyskretyzacja pionowa oznacza najczęściej wprowadzenie od kilkunastu do kilkudziesięciu warstw o stałej lub zmiennej wysokości (porównaj rys. 4).

Struktura modeli eulerowskich stanowi poważny problem i również jest potencjalnym źródłem znacznych błędów w przypadkach, w których chodzi o indywidualne generowanie macierzy przeniesienia dla poszczególnych źródeł emisji. Tego typu analiza jest standardowo wykorzystywana przy wyborze długoterminowej strategii ograniczania emisji lub rozwiązywaniu odpowiednich zadań optymalizacyjnych (porównaj model RAINS [2]). Przypadek występowania izolowanego, dużego źródła punktowego (duże wartości gradientu pola stężenia zanieczyszczeń) jest natomiast, jak wspomniano wyżej, szczególnie wrażliwy z punktu widzenia powstawania czysto numerycznych (nie fizycznych) zniekształceń w rozwiązaniu.

Dokładność prognoz modelu eulerowskiego jest zależna od właściwego dostosowania kroku siatki aproksymacyjnej do struktury modelowanego obszaru. Modele operujące w skali regionalnej z reguły dotyczą obszarów o zmiennej strukturze, np. zróżnicowanej rzeźbie terenu, jego pokryciu, zawierających duże aglomeracje miejsko-przemysłowe wymagające dokładniejszej aproksymacji itp. W zależności od wymiarów oraz charakterystyki przestrzennej obszaru stosowane są modele: a) jednoskalowe, b) dwuskalowe z zagnieźdzeniem c) zmiennoskalowe, adaptacyjne (porównaj rys. 5).



Rys. 5. Rodzaje aproksymacji w modelu eulerowskim: a) jednoskalowa, b) dwuskalowa z zagnieźdzeniem, c) zmiennoskalowa (adaptacyjna) [15].

Pierwszy typ aproksymacji dotyczy obszarów o jednorodnej, niezbyt zróżnicowanej strukturze przestrzennej, gdzie zastosowanie jednej wartości kroku dyskretyzacji pozwala uzyskać wystarczającą dokładność rozwiązania. W przypadku aproksymacji dwuskalowej, model w większej skali (np. regionalny) generuje warunki brzegowe dla dokładniejszego i operującego na gęstszej siatce dyskretyzacji modelu zagnieźdzonego, którego celem jest ocena jakości powietrza, np. w aglomeracji przemysłowej. Aproksymacja zmiennoskalowa (adaptacyjna) ma na celu dostosowanie precyzji dyskretyzacji do zmiennej struktury modelowanego regionu (np. zagęszczenie siatki nad obszarami górskimi, aglomeracjami). Rozwiązania tego typu wymagają oczywiście bardziej skomplikowanych rozwiązań numerycznych i odpowiednio większego nakładu obliczeń.

3. Wpływ danych wejściowych na jakość prognoz

Poza parametrami samego modelu, zasadnicze znaczenie dla dokładności generowanych wyników lub niepewności związanej z prognozami modelu 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 Dane meteorologiczne

3.1.1 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 [9], w którym uwzględnia się wyniki: (a) pomiarów wykonywanych jedynie w wybranych, stosunkowo nielicznych węzłach obszaru (rys. 6a) 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 na rys. 6b.

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 obciążone 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 [9,17].

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.



Rys. 6. Obszar pomiarowy (a). Kolejne kroki tworzenia prognozy numerycznej (b) [9].

W zaawansowanych modelach propagacji zanieczyszczeń atmosferycznych dane meteorologiczne są zwykle przygotowywane przez zewnętrzny preprocesor, działający w większej skali i operujący na „grubszej” siatce dyskretyzacji. Proces asymilacji danych musi w tym wypadku realizować dodatkowo transformację danych na dokładniejszą siatkę modelu rozprzestrzeniania się zanieczyszczeń.

Inny problem pojawia się w przypadku badania wrażliwości lub niepewności prognoz modelu z punktu widzenia wejściowych danych meteorologicznych [1,5,6,17]. Tego typu analiza jest najczęściej prowadzona w oparciu o metody Monte Carlo, co w tym wypadku oznacza konieczność symulowania 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.

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 [7,10]:

$$\begin{aligned} \frac{\partial}{\partial z} \left(K_m(z) \frac{\partial u_o}{\partial z} \right) + \rho f v_o &= \rho f v_g, \\ \frac{\partial}{\partial z} \left(K_m(z) \frac{\partial v_o}{\partial z} \right) + \rho f u_o &= \rho f u_g \end{aligned} \quad (4)$$

z warunkami brzegowymi

$$\begin{aligned} u_o(\bar{e}) &= \bar{u}_a, & v_o(\bar{e}) &= \bar{v}_a, \\ u_o(H_m) &= u_g, & v_o(H_m) &= v_g. \end{aligned}$$

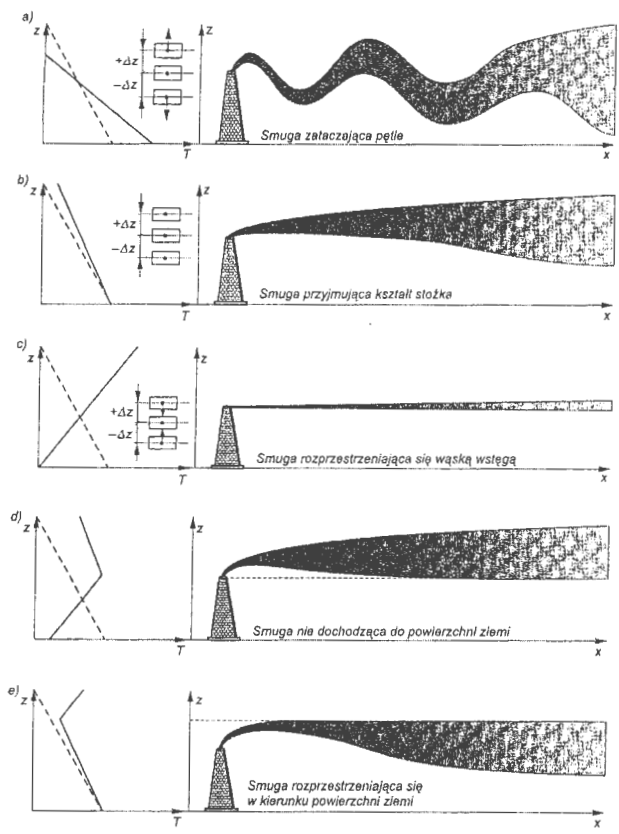
Wektory $w_g = [u_g, v_g]$ oraz $w_a = [u_a, v_a]$ reprezentują, odpowiednio, wiatr geostroficzny oraz anemometryczny (uśrednione dane pomiarowe na wysokości anemometru), natomiast \bar{e} oznacza uśrednioną w modelowanym obszarze elewację terenu, f – współczynnik Coriolisa, K_m – funkcję uniwersalną zależną od warunków stabilności atmosfery [7,10,18].

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. Na rys. 8 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-adiabatycznego* (przemiany w gazach zachodzą bez wymiany ciepła z otoczeniem), który stanowi wartość referencyjną. Gradient sucho-adiabatyczny oznacza spadek temperatury powietrza w funkcji wysokości o ok. 1 °C na każde 100 m (na rys. 7 oznaczono go linią przerywaną).



Rys. 8. Wpływ równowagi atmosfery na transport zanieczyszczeń [10]

Jeżeli aktualny gradient temperatury otaczającego powietrza (linia ciągła na rys. 8) jest większy od sucho-adiabatyycznego, atmosfera jest w stanie niestabilnym, tzn. wzmacniane będą pionowe ruchy zanieczyszczeń emitowanych ze źródła (np. będą się stale unosić, ponieważ ich temperatura jest wyższa niż temperatura otoczenia). Taką sytuację ilustruje rys. 8a). W przeciwnym wypadku, jeżeli gradient temperatury otoczenia jest mniejszy niż sucho-adiabatyyczny – warunki są stabilne, tzn. wszelkie ruchy pionowe emitowanych zanieczyszczeń są w wyniku istniejącej różnicy temperatur (rys. 8c). Jeżeli natomiast gradient temperatury otoczenia jest zbliżony do adiabatycznego – panują warunki neutralne (rys. 8b). Poza tym, możemy w praktyce mieć do czynienia z kombinacją różnych warunków, jeżeli pojawia się inwersja temperatury (rys. 8d-e).

W większości implementacji modeli transportu zanieczyszczeń stabilność atmosferyczna uwzględniana jest poprzez wprowadzenie tzw. klasyfikacji Pasquilla, który wprowadzi 6 klas tego parametru, zgodnie z tabelą [20]:

Tablica 1. Klasy stabilności atmosfery Pasquilla

Klasa równowagi	Charakterystyka
A	równowaga silnie chwiejna
B	równowaga chwiejna
C	równowaga lekko chwiejna
D	równowaga neutralna
E	równowaga lekko stała
F	równowaga stała

Parametr ten nie jest wyznaczany bezpośrednio jako element standardowej prognozy meteorologicznej. Równocześnie zależy on m.in. od prędkości wiatru, pory dnia, zachmurzenia, nasłonecznienia i jego wartość jest szacowana na podstawie tych danych. 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.

3.2 Dane emisyjne

W większości publikacji przeważa pogląd [1,2,12,15], 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.

W zależności od 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 opisanie 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 komin – h , jego średnicy wewnętrznej – d , temperatury gazów odlotowych – T oraz ich prędkości – v_d . W zależności od ilości ciepła emitowanego z komin – $Q(T)$ stosowane są dwie następujące (zalecane przez Ministerstwo Środowiska [20]) formuły obliczeniowe:

a) formuła Hollanda (dla $Q \leq 2 \cdot 10^4$ [kJ/s])

$$H = h + \frac{K}{u_h}, \quad \text{gdzie } K = 1.5v_d + 0.00974 \cdot Q \quad (6)$$

b) formuła CONCAWE (CONservation of Clean Air and Water in Europe)

(dla $Q > 2 \cdot 10^4$ [kJ/s])

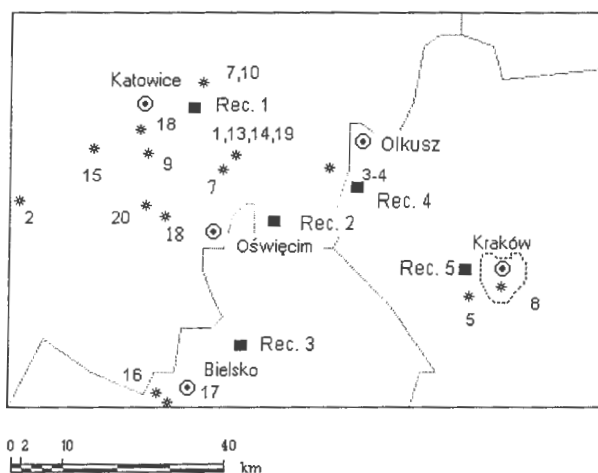
$$H = h + \frac{K}{u_h^{0.7}}, \quad \text{gdzie } K = 1.126 \cdot Q^{0.58} \quad (7)$$

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

W przypadku stosowania tych formuł, obok parametrów dotyczących wielkości emisji, potencjalne źródło 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. Przebieg oraz wyniki obliczeń testowych

Obliczenia testowe dotyczyły oceny niepewności prognoz przeprowadzono na przykładzie regionalnego, trójwarstwowego modelu eulerowskiego REGFOR3 [7,8]. 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 (patrz rys. 9). Dla celów obliczeniowych, obszar zdyskretyzowano jednorodną siatką kwadratową o kroku $h = 2$ km. Na rys. 9 przedstawiony jest obszar obliczeniowy, lokalizacja analizowanych źródeł emisji oraz 5-ciu receptorów, w których rejestrowane były wyniki obliczeń (m.in. w tych punktach szacowano rozkłady prognozowanych przez model wartości stężenia SO_2).



Rys. 9. 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 tabelicy 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.



Rys. 10. Średnio-sezonalny rozkład stężenia SO_2 w obszarze

W tabelicy 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 [5,6,7,12,15] w analizie niepewności ze względu na dane emisyjne przyjmowany jest rozkład log-normalny). Ponieważ różnice w wynikach uzyskanych dla obu rozkładów były nieistotne (decyduje zakres 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 z krokiem 6-godzinny. Wyniki były rejestrowane jako uśrednione za okres symulacji (sezon zimowy) wartości stężenia SO_2 w 5-ciu receptorach zaznaczonych na rysunkach 9 oraz 10.

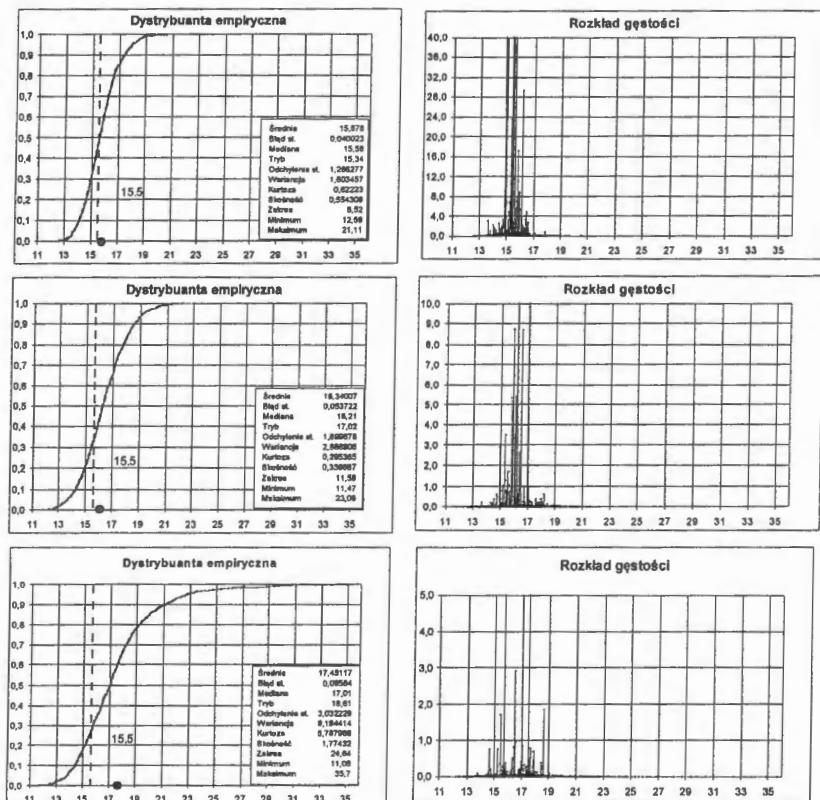
Tablica 2. Parametry źródeł emisji

No	Emitor	Współrzędne 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	SierszaB	(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

Tablica 3. Zmienność danych wejściowych uwzględniana w analizie niepewności

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

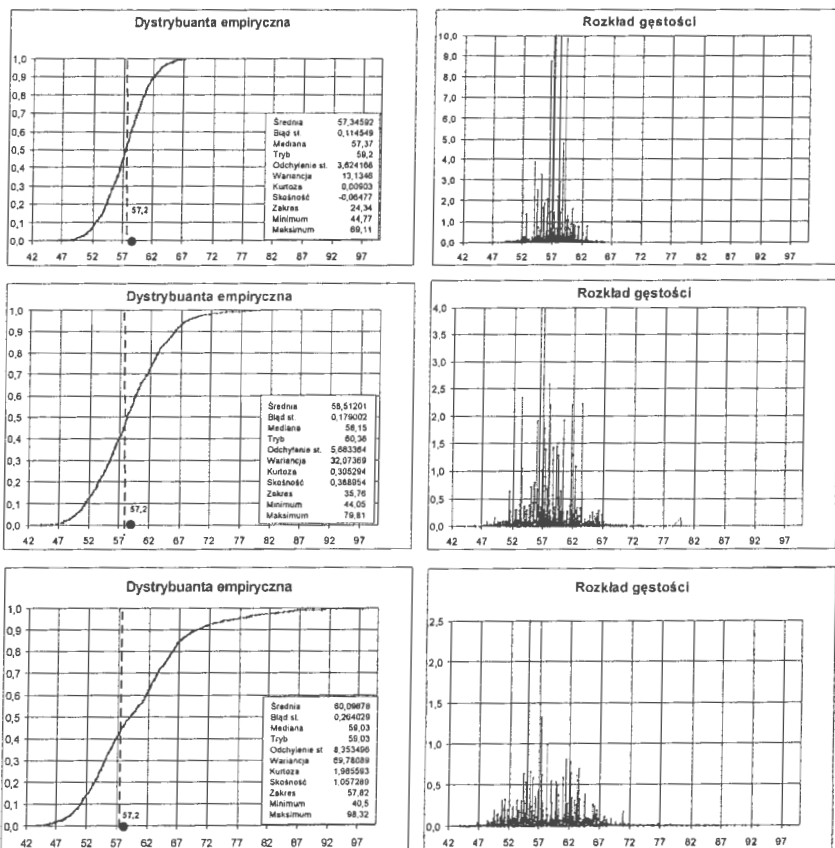
Receptor 1



Rys. 11. Wpływ niepewności danych wejściowych na wyniki (receptor 1):

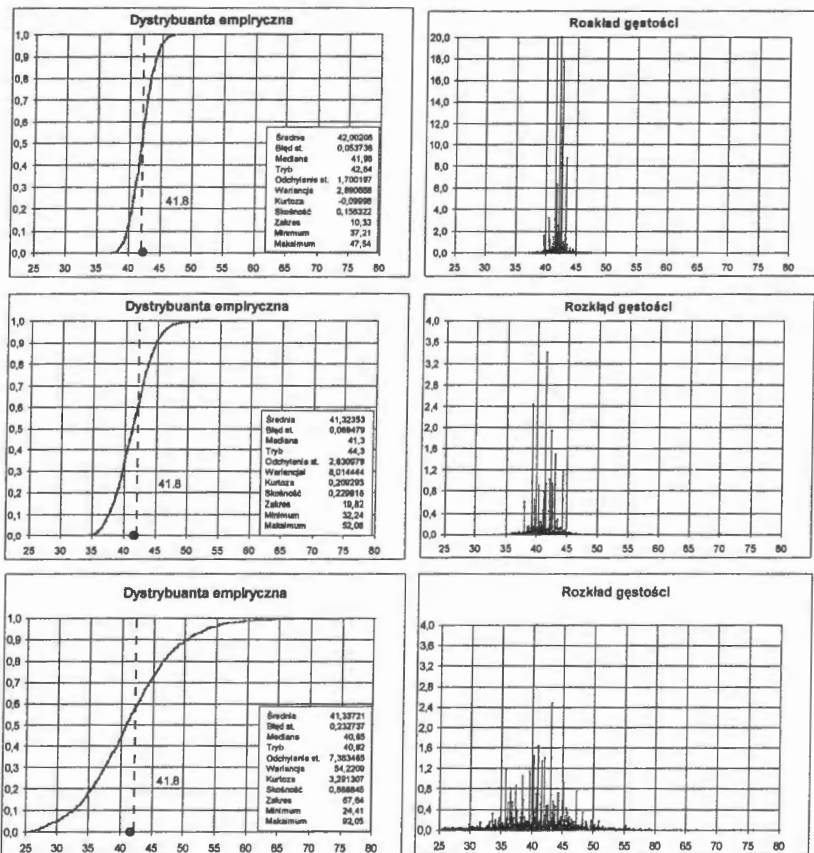
- intensywności emisji źródeł,
- parametrów technicznych źródeł emisji,
- danych meteorologicznych (z pominięciem klasy stabilności atmosfery)

Receptor 2



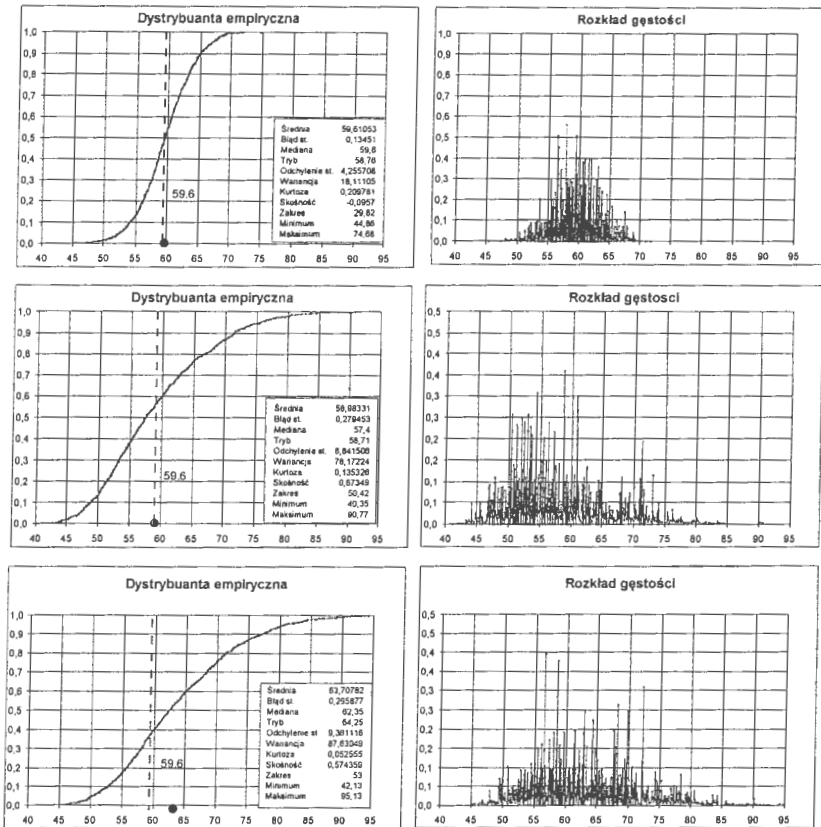
Rys. 12. Wpływ niepewności danych wejściowych na wyniki (receptor 2):
 a) intensywności emisji źródeł,
 b) parametrów technicznych źródeł emisji,
 c) danych meteorologicznych (z pominięciem klasy stabilności atmosfery)

Receptor 3



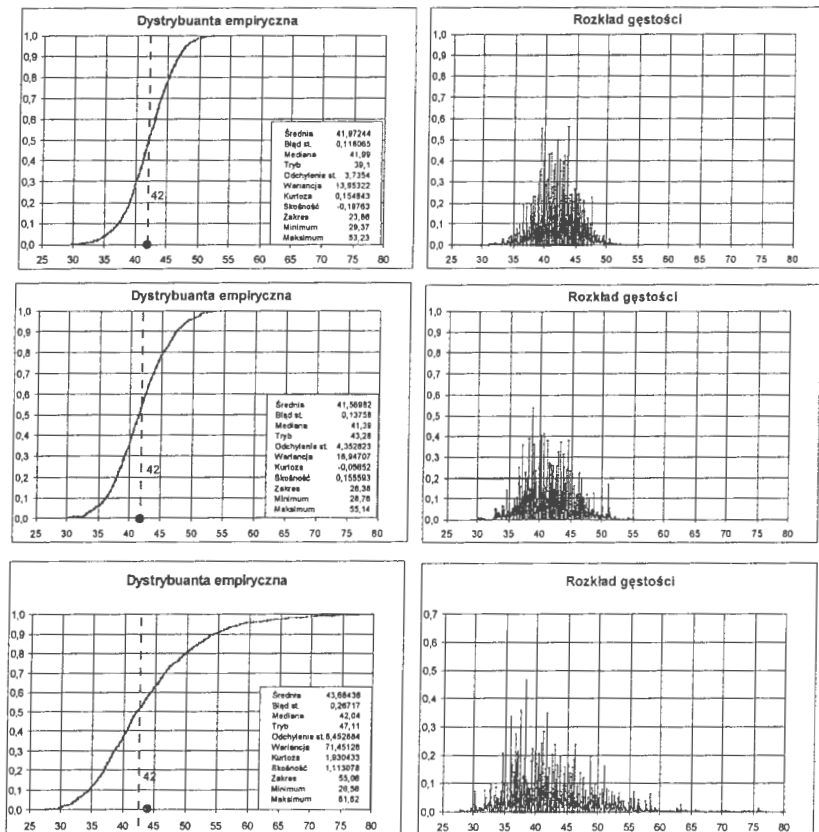
Rys. 13. Wpływ niepewności danych wejściowych na wyniki (receptor 3):
 a) intensywności emisji źródeł,
 b) parametrów technicznych źródeł emisji,
 c) danych meteorologicznych (z pominięciem klasy stabilności atmosfery)

Receptor 4



Rys. 14. Wpływ niepewności danych wejściowych na wyniki (receptor 4):
 a) intensywności emisji źródeł,
 b) parametrów technicznych źródeł emisji,
 c) danych meteorologicznych (z pominięciem klasy stabilności atmosfery)

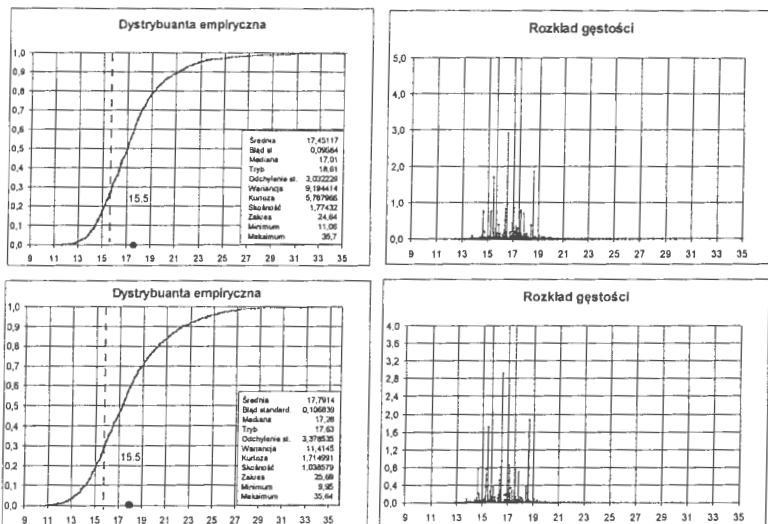
Receptor 5



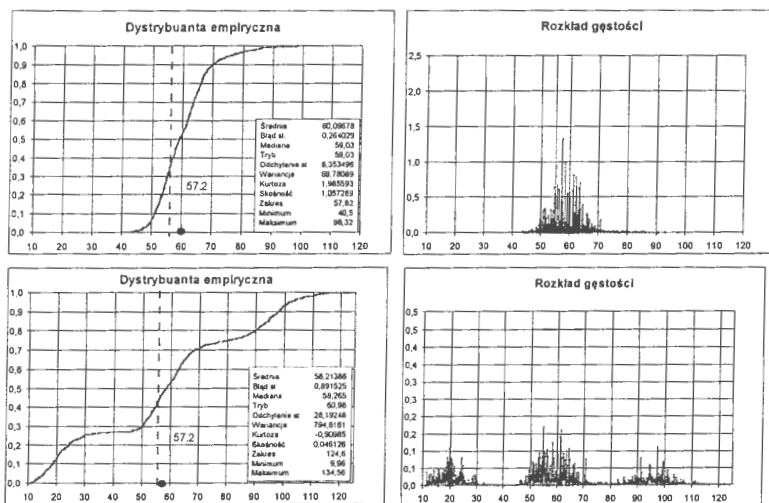
Rys. 15. Wpływ niepewności danych wejściowych na wyniki (receptor 5):

- intensywności emisji źródeł,
- parametrów technicznych źródeł emisji,
- danych meteorologicznych (z pominięciem klasy stabilności atmosfery)

Receptor 1







Receptor 2






Rys. 16. Wpływ niepewności klasy stabilności atmosfery na rozkład końcowy (receptory 1,2)

Receptor 3

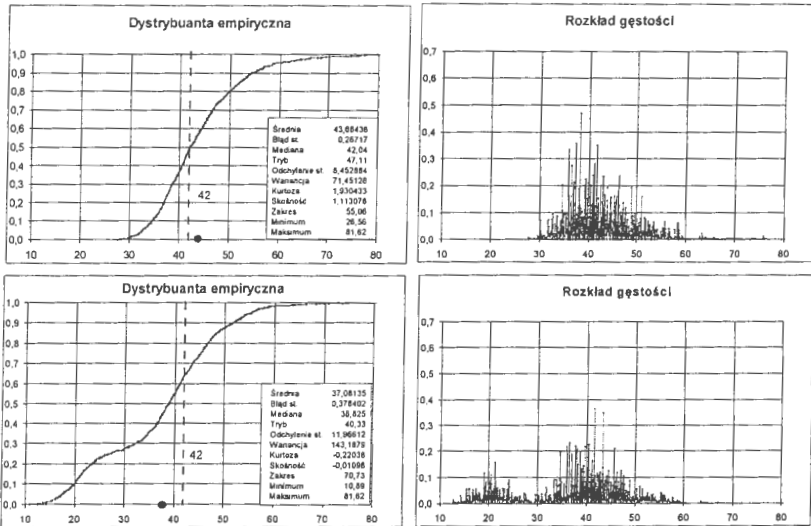


Receptor 4



Rys.17. Wpływ niepewności klasy stabilności atmosfery na rozkład końcowy (receptory 3,4)

Receptor 5




Rys. 18. Wpływ niepewności klasy stabilności atmosfery na rozkład końcowy (receptor 5)

Wybrane wyniki obliczeń przedstawiono na rysunkach 11 – 18. Przedstawiają one kształt dystrybuanty empirycznej rozkładów stężenia zanieczyszczeń w 5-ciu receptorach, uzyskane w wyniku przeprowadzenia 1000 przebiegów modelu prognostycznego przy różnych kombinacjach parametrów wejściowych. Obok wykresu dystrybuanty zamieszczony jest uproszczony histogram reprezentujący rozkład gęstości próbek. Rysunki 11 – 15, dla każdego receptora, przedstawiają trzy zestawy wyników, ilustrujących wpływ niepewności: a) intensywności emisji, b) emisji oraz parametrów technicznych emitora, c) pełnych danych emisyjnych oraz danych meteorologicznych (z wyłączeniem wpływu klasy stabilności atmosfery).


Z kolei rysunki 16 – 18 pozwalają porównać ostatni wynik z tym, jaki uzyskamy uwzględniając dodatkowo niepewność prognozowania klasy równowagi atmosfery. Zgodnie z założeniami przyjętymi w tabelicy 3, niepewność klasy stabilności może wahać się o ± 1 w stosunku do wartości nominalnej. Jak widać, wpływ ten jest bardzo znaczny, przy czym mocno zależy od lokalizacji receptora względem dominujących źródeł emisji (porównaj receptory 2 i 4). W szczególności, w receptorze 2 wyraźnie widoczne są 3 maksima w rozkładzie gęstości próbki, co jest bezpośrednim odbiciem różnych warunków rozprzestrzeniania się zanieczyszczeń dla trzech rodzajów równowagi atmosfery.

a) uwzględnienie intensywności emisji



Rec. 1	Rec. 2	Rec. 3	Rec. 4	Rec. 5
+14%	+10%	+7%	+12%	+14%
15.7	57.3	42	59.6	42
-11%	-10%	-7%	-12%	-15%


b) + parametry techniczne źródła emisji




Rec. 1	Rec. 2	Rec. 3	Rec. 4	Rec. 5
+17%	+16%	+11%	+28%	+18%
16.3	58.5	41.3	59.0	41.6
-16%	-15%	-11%	-20%	-17%

Rys. 19. Wpływ danych emisyjnych na zakres niepewności prognoz stężenia SO₂.

a) uwzględnienie pełnych danych emisyjnych




b) + podstawowe parametry meteorologiczne



Rys. 20. Wpływ danych meteorologicznych (bez klasy stabilności atmosfery) na zakres niepewności prognoz stężenia SO₂

a) uwzględnienie pełnych danych emisyjnych i meteorologicznych

b) + klasa stabilności atmosfery



Rys. 21. Wpływ dodatkowego uwzględnienia klasy stabilności atmosfery na zakres niepewności prognoz stężenia SO₂

Na rysunkach 19 - 21 przedstawiono przykładowe diagramy ilustrujące zakres niepewności stężeń SO_2 generowanych przez model, rejestrowanych w 5-ciu receptorach punktowych, odpowiadające losowej zmienności poziomu emisji analizowanych źródeł (rys. 19), zmienności parametrów meteorologicznych bez uwzględniania klasy stabilności (rys. 20) oraz po uwzględnieniu niepewności wszystkich danych wejściowych (rys. 21).

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 [6,7,12,15]. 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.

Prezentowane wyniki są podstawą do dalszych prac, dotyczących m.in. wpływu niepewności prognoz jakości powietrza na proces podejmowania decyzji. W przygotowywanych obecnie pracach badany jest wpływ parametrów modelu oraz łączny wpływ różnych kategorii danych na końcową dokładność modelu oraz rozwiązania zadań optymalizacyjnych opartych na tym modelu.

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] Alcamo J., Bartnicki J.: A framework for error analysis of a long-range transport model with emphasis on parameter uncertainty. *Atmospheric Environment*, 21 (1987) 2121 – 2131.
- [3] Bergin M.S., Milford J.B. Application of Bayesian Monte Carlo analysis to a Lagrangian photochemical air quality model. *Atmospheric Environment*, 34 (2000) 781 – 792.
- [4] Fisher B.: Fuzzy environmental decision-making: application to air pollution. *Atmospheric Environment*, 37 (2003) 1865 – 1877.
- [5] 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.
- [6] 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.
- [7] Holnicki P. *Modele propagacji zanieczyszczeń atmosferycznych w zastosowaniu do kontroli i sterowania jakością środowiska*, Akad. Oficyna Wydawnicza EXIT, Warszawa (2006).
- [8] Holnicki P. Zastosowanie modeli zintegrowanych do zarządzania jakością powietrza atmosferycznego. *Applications of Informatics in Environment Engineering and Medicine* (ed., O. Hryniewicz, A. Straszak, J. Studziński), Wydawnictwo IBS PAN, Badania Systemowe (2008) tom. 63, 161 – 172,.
- [9] Krzemiński B.: Asymilacja danych w numerycznej prognozie pogody. *Gazeta obserwatora IMGW*, 1 (2005), 4 – 6.
- [10] Markiewicz M. *Podstawy modelowania rozprzestrzeniania się zanieczyszczeń w powietrzu atmosferycznym*. Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa (2004).
- [11] Moore G.E., Londergan R.J. Sampled Monte Carlo uncertainty analysis for photochemical grid models. *Atmospheric Environment*, 35 (2001) 4863 – 4876.
- [12] 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.
- [13] 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.
- [14] Pielke R.A., Sr.: New Directions: The need to assess uncertainty in air quality evaluations. *Atmospheric Environment*, 32 (1998) 1467 – 1468.
- [15] Russel A., Dennis R.: NASTRO critical review of photochemical models and modeling. *Atmospheric Environment*, 34 (2000) 2283 – 2324.
- [16] Sax T., Isakov V.: A case study for assessing uncertainty in local-scale regulatory air quality modeling applications. *Atmospheric Environment*, 37 (2003) 3481 – 3489.
- [17] Seamann N.L.: Meteorological modeling for air quality assessment. *Atmospheric Environment*, 34 (2000) 2231 – 2259.
- [18] Sportisse B.: A review of current issues in air pollution modeling and simulation. *Computational Geosciences*, 11 (2007), 159 – 181.
- [19] Warren R.F., ApSimon H.M.: Uncertainties in integrated assessment modeling of abatement strategies: illustrations with the SAM model. *Environ. Science and Policy*, 2 (1999) 439 – 456.
- [20] *Rozporządzenie Ministra Środowiska z dnia 3 marca 2008 r. w sprawie poziomów niektórych substancji w powietrzu*. Dziennik Ustaw Nr 47, poz. 281.

THE IMPACT OF THE INPUT DATA ON UNCERTAINTY OF THE FORECASTS OF AIR POLLUTION

Abstract

Computer models of air pollution transport are more and more widely used as decision support tools in environmental quality control and protection. 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. The system, except the standard air pollution forecast, enables scenario analysis and regional planning support by evaluation of environmental impact of emission sources. The application of the optimization methods makes it possible to formulate and solve problems of the optimal strategy of emission reduction. However, the structure of the forecasting model itself as well as the input data (emission inventory, meteorological data, computational domain parameters) constitute the significant sources of uncertainty of the model forecasts. In the paper the main sources of uncertainty in modeling of atmospheric pollution are characterized and compared. The Monte Carlo analysis is applied for assessment of modeling uncertainty of a regional-scale model implementation.

Keywords: *atmospheric pollution, pollution dispersion model, uncertainty analysis, integrated system*

the 1990s, the number of people in the world who are illiterate has increased from 1.1 billion to 1.2 billion (UNESCO, 2003).

There are many reasons for the increase in illiteracy. One of the reasons is that the population growth rate is higher than the literacy rate. Another reason is that the quality of education is low. In many countries, the quality of education is so low that it does not help people to become literate. In addition, many people do not have access to education. In many countries, especially in rural areas, there are no schools or the schools are far away from the people's homes. This makes it difficult for people to attend school.

There are many ways to reduce illiteracy. One way is to improve the quality of education. This can be done by training teachers and providing better teaching materials.

Another way is to provide more access to education. This can be done by building more schools and providing transportation for students.

There are also many other ways to reduce illiteracy. For example, people can be taught to read and write through community-based programs.

It is important to reduce illiteracy because it is a major barrier to economic development and social progress.

By reducing illiteracy, we can help people to improve their lives and contribute to the development of their countries.

There are many challenges in reducing illiteracy, but it is worth the effort. We must work together to make a difference.

Let us all do our part to reduce illiteracy and create a better world for everyone.

Thank you for reading this article. I hope it has been helpful to you.

For more information on illiteracy, please visit the website: <http://www.unesco.org/education/illiteracy/>

References: UNESCO (2003) *Global Education Trends*. Paris: UNESCO.

UNESCO (2004) *Education for All: Literacy Skills Development Strategy*. Paris: UNESCO.

World Bank (2003) *World Development Report 2003: Sustainable Development in a Changing World*. Washington, DC: World Bank.

World Bank (2004) *World Development Report 2004: Making the Most of Human Development*. Washington, DC: World Bank.

World Bank (2005) *World Development Report 2005: Doing Better in a Bad World*. Washington, DC: World Bank.

World Bank (2006) *World Development Report 2006: Externalities and Environment*. Washington, DC: World Bank.

World Bank (2007) *World Development Report 2007: The Crisis after the Crisis*. Washington, DC: World Bank.

World Bank (2008) *World Development Report 2008: The World as a Whole*. Washington, DC: World Bank.

World Bank (2009) *World Development Report 2009: Access to Basic Services*. Washington, DC: World Bank.

World Bank (2010) *World Development Report 2010: Development in a Changing World*. Washington, DC: World Bank.

World Bank (2011) *World Development Report 2011: Learning to Realize the Dream of a Better World*. Washington, DC: World Bank.

World Bank (2012) *World Development Report 2012: Gender Equality and Development*. Washington, DC: World Bank.

World Bank (2013) *World Development Report 2013: Jobs for the Future*. Washington, DC: World Bank.