



Prognozowanie stężeń zanieczyszczeń powietrza w GOP-ie modelami statystycznymi

Jarosław Siewior

Wojewódzki Inspektorat Ochrony Środowiska, Katowice

Tadeusz Tumidajski, Dariusz Foszcz, Tomasz Niedoba

Akademia Górniczo-Hutnicza, Kraków

1. Wstęp

Propagację zanieczyszczeń powietrza można opisywać za pomocą modeli deterministycznych, wykorzystujących równania różniczkowe fizyki atmosfery lub modeli fenomenologicznych analizujących statystycznie zebrane dane pomiarowe. Zgodność obu typów modeli z danymi rzeczywistymi jest różna, zakres i sens ich stosowalności także są inne i wielokrotnie wybór modelu jest określony celem jego stosowania [5, 12, 23] oraz posiadanym zbiorem danych.

W przypadku analizy propagacji zanieczyszczeń w dużych aglomeracjach przemysłowych stosowanie modeli deterministycznych jest praktycznie niemożliwe ze względu na potrzeby w zakresie danych (charakterystyka źródeł topografii terenu, charakterystyk meteorologicznych itp.) i dlatego próbuje się wykorzystać fenomenologiczne podejście do problemu opisu propagacji z zastosowaniem różnych technik oblicze-

niowych – od prostych metod statystycznych do sieci neuronowych [1÷4, 6, 11÷17, 22, 23].

Istnieje wiele podejść określających postacie modeli statystycznych wiążących stężenia zanieczyszczeń powietrza z warunkami meteorologicznymi i sytuacjami synoptycznymi które były opracowywane dla wielu aglomeracji oraz różne zespoły badawcze [1, 2, 6, 16, 17]. Nasz zespół także zajmował się przez lata tym zagadnieniem w odniesieniu do Krakowa i GOP-u [7÷10, 18÷21]. W ostatnich latach pojawił się model typu ARX (autoregresja stężeń oraz warunki meteorologiczne), który znalazł elementarne uzasadnienie.

Prezentowany artykuł poświęcony jest próbom wykorzystania opracowanego modelu jako bazy prognoz stężeń zwłaszcza SO_2 , które mogą być stosowane do zarządzania emisją SO_2 poprzez jej ograniczenie (wyłączanie określonych obiektów) a także do ostrzegania ludności miast.

2. Bazowa postać modelu

Wieloletnie badania średniodobowych stężeń SO_2 mierzonych w stacjach zlokalizowanych w miastach GOP-u doprowadziły do następujących wniosków:

- stężenia SO_2 w obu kolejnych dobach są ze sobą skorelowane na bardzo wysokim poziomie istotności;
- można przyjąć, że wraz ze wzrostem prędkości wiatru stężenie SO_2 (średniodobowe) spada, co na wykresie daje kształt paraboli lub hiperboli;
- analogicznie zachowuje się zależność między SO_2 i temperaturą.

Te obserwacje pozwalają na zaproponowanie addytywnej postaci zależności $\text{SO}_2(t)$ i wymienionych wyżej wielkości czyli:

$$\text{SO}_2(t) = a\text{SO}_2(t-1) + b(v - v_0)^2 + c(T - T_0)^2 + d \quad (1)$$

gdzie:

$\text{SO}_2(t)$, $\text{SO}_2(t-1)$ – średniodobowe stężenia SO_2 w dniach t i $t-1$,
 v i T – średnie prędkości wiatru i temperatury powietrza w dniu t ,
 v_0 i T_0 – przyjęte współrzędne (odcięte) wierzchołków parabol.

Tabela 1. Modele średniodobowych zanieczyszczeń powietrza SO₂ dla Zabrze w sezonach grzewczych 2005/2006, 2006/2007, 2008/2009, 2009/2010

Table 1. Models of daily average SO₂ air pollution for Zabrze for heating seasons 2005/06, 2006/2007, 2008/09, 2009/10

| Sezon 2005/2006 |
|---|
| $S(t) = -25,42 + 0,591 \cdot S(t-1) + 0,119 \cdot (T-T_0)^2 + 1,505 \cdot (v-v_0)^2$ <p style="text-align: center;">[9,946] [0,0558] [0,0219] [0,4025]</p> |
| <p>R² = 61,51%, S_r = 25,921 v₀ = 6 m/s T₀ = 5°C</p> |
| Sezon 2006/2007 |
| $S(t) = 0,95 + 0,516 \cdot S(t-1) + 0,037 \cdot (T-T_0)^2 + 0,481 \cdot (v-v_0)^2$ <p style="text-align: center;">[3,036] [0,0613] [0,0249] [0,1312]</p> |
| <p>R² = 32,41%, S_r = 10,006 v₀ = 6 m/s T₀ = 5°C</p> |
| Sezon 2008/2009 |
| $S(t) = -13,11 + 0,515 \cdot S(t-1) + 0,091 \cdot (T-T_0)^2 + 0,982 \cdot (v-v_0)^2$ <p style="text-align: center;">[4,485] [0,0555] [0,0181] [0,1864]</p> |
| <p>R² = 51,58%, S_r = 13,942 v₀ = 6 m/s T₀ = 5°C</p> |
| Sezon 2009/2010 |
| $S(t) = -21,11 + 0,570 \cdot S(t-1) + 0,075 \cdot (T-T_0)^2 + 1,334 \cdot (v-v_0)^2$ <p style="text-align: center;">[5,508] [0,0502] [0,0115] [0,2324]</p> |
| <p>R² = 67,51%, S_r = 14,323 v₀ = 6 m/s T₀ = 5°C</p> |

Tabela 2. Statystyki opisowe zmiennych: ditlenek siarki (SO₂), prędkość wiatru oraz temperatura, dla Zabrze w sezonach 2005/2006, 2006/2007, 2008/2009, 2009/2010

Table 2. Descriptive statistics for variables: sulfur dioxide (SO₂), wind velocity and temperature for Zabrze, seasons 2005/06, 2006/07, 2008/09, 2009/10

| | <i>n</i> ważnych | Średnia | Minimum | Maksimum | Odczylenie Standardowe |
|---|------------------|---------|---------|----------|------------------------|
| Zabrze 2005/2006 | | | | | |
| Ditlenek siarki (SO ₂) [μg/m ³] | 149 | 48,30 | 2,00 | 242,00 | 41,21 |
| Prędkość wiatru [m/s] | 182 | 1,19 | 0,10 | 3,20 | 0,59 |
| Temperatura [°C] | 182 | -0,29 | -22,20 | 15,30 | 6,72 |
| Zabrze 2006/2007 | | | | | |
| Ditlenek siarki (SO ₂) [μg/m ³] | 182 | 23,21 | 3,95 | 57,26 | 12,16 |
| Prędkość wiatru [m/s] | 182 | 1,61 | 0,40 | 4,25 | 0,69 |
| Temperatura [°C] | 182 | 3,59 | -7,88 | 16,02 | 4,60 |
| Zabrze 2008/2009 | | | | | |
| Ditlenek siarki (SO ₂) [μg/m ³] | 181 | 28,55 | 2,00 | 88,00 | 19,95 |
| Prędkość wiatru [m/s] | 182 | 1,31 | 0,10 | 3,30 | 0,64 |
| Temperatura [°C] | 182 | 0,25 | -13,60 | 12,30 | 5,69 |
| Zabrze 2009/2010 | | | | | |
| Ditlenek siarki (SO ₂) [μg/m ³] | 182 | 34,03 | 2,68 | 137,83 | 25,13 |
| Prędkość wiatru [m/s] | 182 | 1,32 | 0,47 | 2,98 | 0,51 |
| Temperatura [°C] | 182 | -1,04 | -18,13 | 15,48 | 6,78 |

Model ten został szeroko omówiony w pracy [19]. Analogiczny model został zaproponowany dla Wiednia, przy czym wykorzystano w nim uogólnione zależności hiperboliczne [1].

Przykładem zastosowania modelu (1) do opisu zmian średniodobowych zanieczyszczeń SO₂ w okolicach stacji pomiarowej w Zabrzu są modele zamieszczone w tab. 1. Warto zwrócić uwagę, że współczynniki tych równań (modeli *a posteriori*) są praktycznie stabilne (nie zmieniają

się bardzo w kolejnych okresach – analizowanych sezonach grzewczych (zwłaszcza przy $SO_2(t-1)$), co może być interpretowane na korzyść poprawności wyboru postaci modelu. Współczynniki wszystkich równań są istotne (ich błędy znajdują się w nawiasach kwadratowych) oraz istotne są także współczynniki korelacji wielokrotnej R .

Biorąc pod uwagę fakt, że punkty o współrzędnych będących wartościami średnimi rozpatrywanych zmiennych spełniają badane równanie regresji można na podstawie tab. 2 stwierdzić że największy wpływ na kształtowanie się stężeń $SO_2(t)$ ma stężenie $SO_2(t-1)$ około 40÷50%, potem prędkość wiatru około 40÷45% i wreszcie temperatura około 5÷10%. Wynika z tego też że współczynnik przy $SO_2(t-1)$ przejmuje pewien ułamek wpływu temperatury.

Przedstawione równania regresji mogą być podstawą do realizacji zadań prognozowania stężeń zanieczyszczeń średniodobowych powietrza.

3. Metodyka prognozowania stężeń zanieczyszczeń powietrza

Biorąc pod uwagę naturę procesów, zmienne charakterystyki sezonów grzewczych (warunki meteorologiczne, zmiany ilości i jakości emitorów zanieczyszczeń), należy dokładnie przeanalizować możliwości prognozowania średniodobowych wartości zanieczyszczeń dla obszaru którego stan środowiska objęty jest badaniami danej stacji pomiarowej. Generalnie rzecz biorąc, można przyjąć trzy rozwiązania w zakresie sposobów prognozowania:

- a) aktualizacja bieżąca modeli matematycznych;
- b) stosowanie „ruchomych” modeli matematycznych z użyciem wag czasowych danych;
- c) bieżąca adaptacja modeli, wykorzystująca antygradientowe określenie współczynników na podstawie bieżącej weryfikacji zgodności prognoz z rzeczywistością; [7, 9, 10, 19÷21].

Przez bieżącą aktualizację modeli matematycznych będziemy rozumieć procedurę polegającą na przyjęciu za podstawę wyznaczania współczynników prognozowanego modelu n zestawów danych (rekordów zgodnych z czasem obserwacji) na podstawie którego przeprowadza się prognozę na dzień $(n + 1)$ – szy, wykorzystując prognozy wartości T

i v. Prognozę na dzień $(n + 2)$ – przeprowadza się w oparciu o przeliczony model dla danych w których pomija się dane za dzień pierwszy a wprowadza się dane z dnia $(n + 1)$ – go.

Modele z użyciem wag czasowych danych wyznacza się minimalizując sumę ważonych kwadratów odchyłeń

$$S = \sum_{i=1}^k w_i (S_i - \hat{S}_i)^2 \quad (2)$$

gdzie S_i oznacza rzeczywistą wartość stężenia w i – tym dniu, \hat{S}_i – ocenę wartości stężenia na podstawie modelu w i – tym dniu a w_i – wagę zestawu danych używanych w obliczeniach, przy czym $w_i = \frac{1}{k-i+1}$. Dla liniowego modelu $\hat{S}_i = ax_i + b$ (x_i – zmienna niezależna) stosuje się wzory

$$a = \frac{\overline{xS} - \bar{x} \cdot \bar{S}}{\overline{x^2} - \bar{x}^2}, \quad b = \bar{S} - a \cdot \bar{x} \quad (3)$$

gdzie nadkreślenia oznaczają uśrednianie względem sumy wag i np.

$$\overline{x_s} = \frac{\sum_{i=1}^k w_i S_i x_i}{\sum_{i=1}^k w_i} \quad (4)$$

Zasady przeprowadzania prognoz oraz wyznaczania kolejnych modeli analogiczne jak opisane wyżej.

Adaptacja modeli wykorzystująca antygradientowe określenie współczynników na podstawie bieżącej weryfikacji zgodności prognoz z rzeczywistością, przebiega wg następującego ogólnego schematu [8, 10, 19÷21].

Przyjmując ogólniej, że model prognoz zanieczyszczeń ma postać

$$S_i(t) = f(\mathbf{X}_i, \mathbf{C}_i) = \sum_{j=1}^r c_j \varphi_j(\mathbf{X}_i) \quad (5)$$

gdzie:

\mathbf{X}_i – wektor zmiennych niezależnych,

C_i – wektor współczynników dla i -tego zestawu danych określających X_i ,
 $j = 1, \dots, r$; $i = 1, \dots, N$, $N \geq k$;

$\varphi_j(X_i)$ – wyspecyfikowany układ funkcji wielu zmiennych niezależnych liniowo.

Jeżeli otrzymamy nowy zestaw danych X_{i+1} i chcemy uzyskać na ich podstawie wartość $S_{i+1}(t)$ powinniśmy skorygować współczynnik C_i na C_{i+1} opierając się na korekcie rozbieżności między $S_i(t)$ określonej z modelu (5) i rzeczywistej wartości zanieczyszczenia $S_i(t)$, czyli:

$$q_{i+1}(C_i) = f(X_{i+1}, C_i) - S_{i+1}(t) \quad (6)$$

Wartość poprawki ΔC_{i+1} powinna być taka aby zmniejszać kwadrat tej różnicy. Osiąga się to metodą „antygradientową”, przyjmując że

$$\Delta C_{i+1} = -\alpha_{i+1} \nabla q_{i+1}^2(C_i) \quad (7)$$

gdzie:

α_{i+1} – dodatni współczynnik,

∇ – operator nabra, $\nabla = \left(\frac{\partial q}{\partial c_1}, \dots, \frac{\partial q}{\partial c_k} \right)$

Po przeprowadzeniu obliczeń otrzymuje się wzór na:

$$\alpha_{i+1} = \frac{1}{2} \left[C_{0i} + \sum_{j=1}^r c_{ji} \varphi_{ji}^2(\mathbf{X}_{i+1}) \right]^{-1} \quad (8)$$

gdzie: X_{i+1} – układ współrzędnych wektora wejść X w chwili $i+1$.

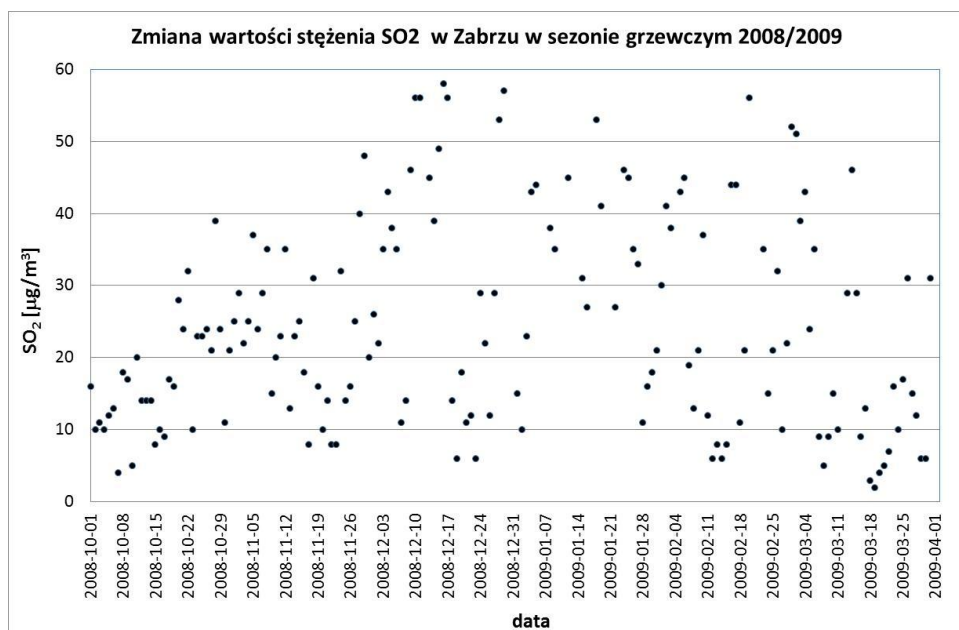
4. Weryfikacja metod prognozowania

Przedstawiamy w rozdziale drugim model bazowy (a posteriori) nie może być podstawą uzasadnionej prognozy stężeń SO_2 z dwóch powodów: po pierwsze – każdy okres chłodny cechuje się swoimi współczynnikami w modelu i nie można go przenieść na okres następny (tab. 1); po drugie – w trakcie okresu chłodnego (grzewczego) zmienia się ranga wpływu rozważanych zmiennych na stężenie $SO_2(t)$. Analizę tych

spostrzeżeń przedstawimy na przykładzie okresu grzewczego 2008/09, dla którego dane były rejestrowane na stacji pomiarowej w Zabrze.

Na rys. 1 pokazano rozkład wartości $SO_2(t)$ pomierzonych w Zabrzu. Przyjmuje się ogólnie, że zależność $SO_2(t)=f(t)$ opisuje się parabolą ponieważ stężenia $SO_2(t)$ na początku i końcu okresu grzewczego są względnie niewielkie i zwiększają się w środku okresu. Rys. 1 potwierdza tę zależność i zimę 2008/09 można uznać za typową.

Zgodnie z propozycjami omówionymi w rozdziale trzecim, symulację prognozowania przeprowadzono na danych związanych z rys. 1, traktując dane dotyczące prędkości wiatru i temperatury z dnia o numerze t jako prognozy.



Rys. 1. Zmiana wartości stężenia SO_2 w trakcie sezonu grzewczego 2008/2009
Fig. 1. Change of SO_2 concentration during heating season 2008/09

Kolejne modele regresyjne i modele z wagami wyznaczono na podstawie 30-dniowych zestawów danych. Wyniki obliczeń (wartości współczynników modeli) przedstawiono w tab. 3. Można zauważyć, że obie metody modelowania dają podobne wyniki (zbliżone wartości

współczynników); w okresie października zmienna $(T-T_0)^2$ ma ujemny wpływ na stężenie $SO_2(t)$ temperatury średnie są wyższe od 5°); w miesiącach typowo zimowych rośnie wpływ zmiennej $(v-v_0)^2$.

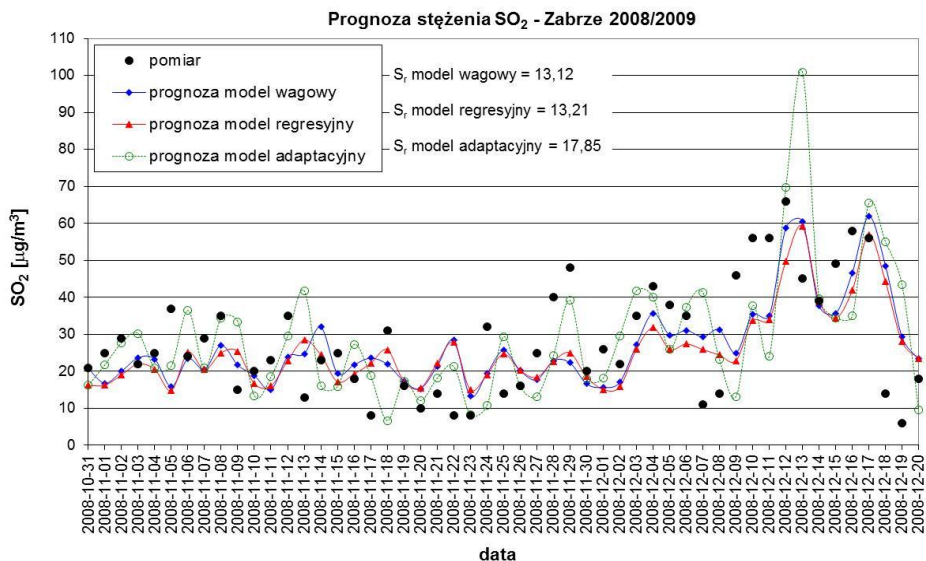
Tabela 3. Wartości współczynników w modelach prognoz stężenia (dane za okres 30 dni)

Table 3. Values of coefficients in models of concentration forecast (data for 30 days)

| model w dniu | Model regresyjny | | | | Model wagowy | | | |
|-----------------|------------------|-------------|-------------|-------------|--------------|-------------|-------------|-------------|
| | w w | $(v-v_0)^2$ | $(T-T_0)^2$ | $SO_2(t-1)$ | w w | $(v-v_0)^2$ | $(T-T_0)^2$ | $SO_2(t-1)$ |
| 31.10.2008 | 5,85 | 0,248 | -0,118 | 0,346 | 8,01 | 0,416 | -0,185 | 0,142 |
| 30.11.2008 | -2,50 | 0,957 | 0,039 | 0,135 | -4,43 | 1,248 | -0,009 | 0,042 |
| 31.12.2008 | -16,34 | 1,182 | 0,086 | 0,643 | -21,34 | 1,233 | 0,103 | 0,718 |
| 30.01.2009 | -7,87 | 1,776 | 0,067 | 0,139 | -3,86 | 1,725 | 0,066 | 0,095 |
| 28.02.2009 | -32,41 | 1,966 | 0,090 | 0,439 | -36,19 | 1,897 | 0,143 | 0,405 |
| 30.03.2009 | -12,45 | 0,849 | 0,053 | 0,653 | -6,88 | 0,457 | 0,100 | 0,617 |

Przykładowe wyniki prognoz opisanymi trzema metodami przedstawiono na rys. 2. Wartości s_r były wyznaczone według wzorów określających odchylenie resztowe. Należy wyraźnie podkreślić, że wykazują one zmienność zależną od okresu, w którym są rozpatrywane a także od zmienności wartości $SO_2(t)$. Okazało się, że najdokładniejsze prognozy podaje model wagowy, trochę gorsze – nadążny model regresyjny a najgorsze model adaptacyjny.

Model adaptacyjny ma tę właściwość, że zmienia wartość współczynników, w pewnym sensie, proporcjonalnie do ich wartości, w zależności od wartości różnicy $SO_2(t+1)$ i jej prognozy. Wprowadzone poprawki wpływają korzystnie na dokładność prognozy gdy stężenia $SO_2(t)$ wykazują tendencje wzrostowe lub spadkowe, w przypadku zmian tendencji model adaptacyjny daje pogorszenie prognoz. Rys. 2 jest bardzo dobrą ilustracją opisanych zachowań modelu.



Rys. 2. Prognoza wartości stężenia SO₂ w Zabrzu modelami wagowym, regresyjnym i adaptacyjnym dla wybranego okresu 31.10.2008÷20.12.2008

Fig. 2. Forecast of SO₂ concentration in Zabrze by weight, regressive and adaptive models for chosen period 31.10.2008-20.12.2008

5. Wnioski końcowe

Zaprezentowane wyniki badań dotyczące zastosowania modeli statystycznych propagacji zanieczyszczeń powietrza i wykorzystania danych pochodzących ze stacji pomiarowych rozmieszczonych w obszarze GOP-u są wynikiem długoletnich prac w tym zakresie, które miały także inne cele i zadania niż prognozowanie stężeń SO₂. Pozostając w zakresie prezentowanej tematyki można sformułować kilka wniosków.

1. Udokumentowane heurystycznie modele statystyczne pozwalają stwierdzić, że przy jednoznacznej sytuacji synoptycznej odznaczającej się niskimi temperaturami średnimi i bezwietrzną pogodą można oczekiwać przekroczeń dopuszczalnych wartości stężeń zanieczyszczeń. Jest to przejaw zgodności modeli z rzeczywistością. Przykładem tego jest odnotowany przed końcem 2010 roku smog w Krakowie, przy opisanych wyżej warunkach meteorologicznych.
2. Można stwierdzić, że zaprezentowane w artykule metody prognozy sprawdzają się, przy czym najlepsze są modele oparte o dane z wa-

gami uwzględniającymi ich aktualność. Jeżeli współczynniki takiego modelu przyjmie się za podstawę modelowania adaptacyjnego dla przewidywanych okresowych wzrostów lub obniżek stężeń SO_2 , to wyniki prognozowania będą dokładniejsze.

3. Dokładniejsze oceny technik prognozowania można uzyskać tylko po efektywnym ich wdrożeniu w trakcie wybranego okresu chłodnego dla stacji pomiarowej.
4. Zastosowanie statystycznych metod opisu danych pomiarowych ze stacji pozwala na dokładniejszą ich interpretację oraz udokumentowanie istniejących zależności ilościowych a nawet jakościowych, na co nie zawsze pozwalają czysto numeryczne metody modelowania, czy prognozowania (np. sieci neuronowe).

Literatura

1. **Bolzern P., Fronza G., Runze E., Uberhuber C.:** *Statistical analysis of winter sulphur dioxide concentration data in Vienna*. Atmosph. Envir., vol. 16 no 8, pp. 1899÷1906, 1982.
2. **Bringfelt B.:** *Important factors for the sulphur dioxide concentration in central Stockholm*. Atmosph. Envir. vol. 5, pp. 949÷972, 1971.
3. **Carach V., Mačala J.:** *Modelovanie znečistenia ovzdušia z cestnej dopravy*. Ochrana ovzdušia 2008, Vysoke Tatry – Strbske Pleso, pp. 173÷180, Bratislava, 2008.
4. **Carach V., Mačala J.:** *Road traffic NO_x emissions from passenger cars*. Transport and Logistics, vol. 12, pp. 37÷54, Košice, 2007.
5. **Juda J., Chróściel S.:** *Ochrona powietrza atmosferycznego*. WNT, Warszawa, 1974.
6. **Finzi G., Tebaldi G.:** *A mathematical model for air pollution forecast and alarm in an urban area*. Atmosph. Envir., vol. 16, no 9, pp. 2055÷2090, 1982.
7. **Foszcz D., Gawenda T., Kunysz J., Tumidajski T.:** *Modele adaptacyjne jako metoda prognozowania średniodobowych stężeń SO_2* . Ochrona Powietrza i Problemy Odpadów nr 3/2001, 2001.
8. **Foszcz D., Gawenda T., Siewior J., Tumidajski T.:** *Modele prognoz średniego dobowego stężenia SO_2 dla wybranych miast Górnośląskiego Okręgu Przemysłowego*. Ochrona powietrza i problemy odpadów, Wydawnictwo Naukowo-Techniczne EcoEdycja, rok XXXIV – 2000, nr 5 (199), 174÷179, 2000.

9. **Foszcz D., Niedoba T., Siewior J., Tumidajski T.:** *Stochastic models of air pollutants spreading as the method of emission amount management allowing elimination of high pollution concentrations in ecosystems.* Environmental Management Accounting and Cleaner Production Conference, CD, Graz, Austria, 2006.
10. **Foszcz D., Niedoba T., Siewior J.:** *The methods of forecasting of SO₂ and suspended dust concentrations for warning purposes in the example of selected polluted regions in Poland.* in Ecosystems and Sustainable Development V, red. E. Tiezzi, C.A. Brebbia, S.E. Jorgensen and D. Almorza Gomar, pp. 477÷491, WIT Press, Southampton, Boston, Great Britain, 2005.
11. **Holnicki-Szulc P.:** *Modele propagacji zanieczyszczeń atmosferycznych w zastosowaniu do kontroli i sterowania jakością środowiska,* Akademicka Oficyna Wydawnicza EXIT, Warszawa, 2006.
12. **Markiewicz M.T.:** *Podstawy modelowania rozprzestrzeniania się zanieczyszczeń w powietrzu atmosferycznym.* Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa, 2004.
13. **Morawska-Horawska M.:** *Stochastyczne modele prognozy średniego dobowego stężenia SO₂ dla Krakowa,* Wiadomości IMGW, t. IX, z. 3, 1988.
14. **Morawska-Horawska M., Kuroś E.:** *Specyfika kształtowania się wielkości emisji SO₂ na obszarze GOP i możliwości prognozowania średnich dobowych stężeń SO₂.* Ochrona Powietrza i Problemy Odpadów. Nr 6/1992, s. 148÷150, 1992.
15. **Pomorska K., Duda A.:** *Porównanie poziomu stężeń tlenków azotu w powietrzu na wybranych skrzyżowaniach ulic miasta Lublina w latach 2004 i 2005.* Zeszyty Naukowe Wydziału Budownictwa i Inżynierii Środowiska, Politechnika Koszalińska, pp. 209÷219, Koszalin-Darłówek, 2007.
16. **Rastrigin L. A.:** *Contemporary principles to control complex objects.* Mir Publishers, Moscow, 1983.
17. **Skrzypski J.:** *Analiza i modelowanie pól imisji zanieczyszczeń powietrza w dużych miastach.* Polska Akademia Nauk, Łódź, 2001.
18. **Tumidajski T., Foszcz D., Gawenda T.:** *The principles of the building of average daily gas pollutants stochastic models for municipal agglomeration.* VI Conference on Environment and Mineral Processing, Czech Republic, Ostrava, 2002.
19. **Tumidajski T., Foszcz D., Niedoba T., Siewior J.:** *Ocena napływu zanieczyszczeń powietrza różnymi metodami statystycznymi.* Zeszyty Naukowe Wydziału Budownictwa i Inżynierii Środowiska, no 23, Koszalin – Darłówek, Wydawnictwo Uczelniane PK, 2007.

20. **Tumidajski T., Foszcz D., Siewior J.:** *Wpływ lokalizacji stacji pomiarowych na efekty modelowania stochastycznego stężeń SO_2 w Górnośląskim Okręgu Przemysłowym*. Zeszyty Naukowe Wydziału Budownictwa i Inżynierii Środowiska, no 22, Koszalin – Ustronie Morskie, Wydawnictwo Uczelniane PK, 2005.
21. **Tumidajski T., Foszcz D., Niedoba T., Siewior J.:** *Modele stochastyczne zanieczyszczeń powietrza w aglomeracjach przemysłowych*. Rocznik Ochrona Środowiska, t. 11, cz. 1, pp. 543÷554, 2009.
22. **Walczewski J.:** *Charakterystyka warstwy granicznej atmosfery nad miastem (na przykładzie Krakowa)*. Materiały badawcze IMGW, Seria Meteorologia, no 22, 1994.
23. **Zwoździak J.:** *Prognozy i analizy stężeń zanieczyszczeń w powietrzu w regionie Czarnego Trójkąta*. Oficyna Wydawnicza Politechniki Wrocławskiej, Wrocław, 1998.

Prediction of Air Pollutants Concentrations in GOP Using Statistical Models

Abstract

Predicting of pollutants concentrations is very crucial for big cities and industrial agglomerations. It allows introduction of possible preventive activities with purpose of prevention to accumulation of concentrations as well warning people of possible states being dangerous to health for people from risk group, i.e. elders, people with cardiovascular diseases or people with respiratory system diseases.

Upper Silesian Industrial Region (GOP) is one of the most polluted regions in Poland. Because of the location of several important heavy industrial plants it is necessary to constantly monitor concentrations of various dust and gas pollutants in this area. The paper presents the possibilities of stochastic modeling of air pollutants on the basis of data collected by monitoring stations and their application to pollutants concentrations forecasting. The data from following heating seasons from monitoring station in Zabrze concerning SO_2 concentrations was applied to the analysis. The obtained models were statistically evaluated.

Efficient modeling of daily SO_2 concentrations should be based on regressive models with weights as well on adaptive approach to concentrations modeling dependably on forecasted synoptic situations.

Documented heuristically statistical models allow to state that at unambiguous synoptic situation distinguished by low temperatures and windless weather, average limit values of concentrations of pollutants are expected to be exceeded. It is a manifestation of the compatibility of models with reality. An example of this is smog in Cracow recorded before the end of 2010, at meteorological conditions described above.

The use of statistical methods of description of measurement data from the station allows for more accurate interpretation and documentation of the existing quantitative and even qualitative dependencies, which is not provided by purely numerical methods of modeling and predicting (e.g. neural networks).