

Analiza wyników pomiarów imisji metodami niestrukturalnymi

Procesy i zjawiska zwykle opisuje się metodami strukturalnymi. Modele buduje się na podstawie teorii. Dane doświadczalne w tym wypadku służą do weryfikacji teorii i wyznaczania współczynników równań opisujących proces lub zjawisko. Ten sposób postępowania trwa długo i wymaga znacznych nakładów finansowych.

Drugi sposób, niestrukturalny polega na wnioskowaniu o procesie bezpośrednio na podstawie wyników pomiarów. Znane są podstawy tego ujęcia i aplikacje w postaci programów komputerowych. Metody te zalicza się do sztucznej inteligencji obliczeniowej. Są one stosowane w różnych dyscyplinach. W tej pracy użyto tych metod do analizy wyników pomiarów na stacjach monitoringu powietrza.

Część ogólna

W ocenie jakości powietrza obowiązują skodyfikowane systemy. Wykorzystuje się w nich metody modelowania matematycznego transportu atmosferycznego oraz metody oceny bezpośrednio na podstawie wyników pomiarów. Preferowany jest sposób drugi.

W teorii propagacji zanieczyszczeń stosuje się modele strukturalne Gaussa, Eulera bądź Lagrange'a. Zostały one opisane w książkach [1–3], monografiach [4–8], pracach doktorskich [9–13] i licznych publikacjach [14–24]. W pracy [25] zamieszczono przegląd polskich modeli rozprzestrzeniania się zanieczyszczeń atmosferycznych. Natomiast w pracy [26] podano wskazówki metodyczne dotyczące modelowania matematycznego w systemie zarządzania jakością powietrza. Skodyfikowane są też aplikacje tych modeli w postaci zalecanych programów komputerowych. Osobnym zagadnieniem jest wyznaczanie współczynników modeli transportu atmosferycznego [27–29].

W wypadku analizy wyników pomiarów imisji występują inne zagadnienia. W szczególności dotyczą one wyznaczania charakterystyk probabilistycznych mierzonych wielkości. Pierwsze prace z tego zakresu opublikował Larsen [30, 31]. Stosował rozkłady jednowymiarowe. Stwierdził, że najczęściej był spełniany przez dane doświadczalne rozkład lognormalny. W późniejszym okresie temu zagadnieniu poświęcono wiele publikacji [10, 16, 21, 32–35]. Sztuczne sieci neuronowe w ocenie jakości powietrza stosowano w pracach [8, 12, 13, 36–38].

Rejestrowane na stacjach monitoringu wielkości są zmiennymi losowymi. Mierzone w czasie wyznaczają szeregi czasowe. W stosownych teoriach przeważają modele deterministyczne, a ogólniej modele strukturalne. W razie złożonych procesów lub zjawisk (propagacja zanieczyszczeń jest takim procesem) zwykle trudno zbudować dostatecznie dokładną teorię. Trzeba też

dodać, że uzyskanie danych do obliczeń z zastosowaniem modeli strukturalnych jest kosztowne, a często nawet niemożliwe.

Tego typu zagadnienia występują w różnych dyscyplinach. Dla opisu takich zjawisk zostały opracowane niestrukturalne systemy analizy, wykorzystujące bezpośrednio dane doświadczalne [39, 40]. Istnieją dobre podstawy tych metod oraz aplikacje w postaci programów komputerowych [41–44]. Metody te są zaliczane do sztucznej inteligencji obliczeniowej [8, 39]. Znalazły liczne zastosowania. Są nadal rozwijane.

Dzisiaj często dysponujemy obszernymi i wszechstronnymi danymi o procesie lub zjawisku. Mamy też świadomość wielkiej wagi tych danych. Trudność sprawia zastosowanie właściwych metod analizy statystycznej. Klasyczne (tradycyjne) metody statystyczne są dzisiaj niewystarczające. Celem tradycyjnej analizy danych jest najczęściej weryfikacja hipotezy, albo weryfikacja teorii. Natomiast w praktyce zazwyczaj chodzi o jak najszybsze uzyskanie prostej odpowiedzi, potrzebnej do podjęcia decyzji. Metody zgłębiania danych dostarczają takich informacji [40–44]. Nowe metody nie eliminują starych, sprawdzonych systemów. Wymagają natomiast efektywniejszego ich wykorzystania. Warunkiem koniecznym poprawności analizy jest posiadanie odpowiednich danych. Trzeba dodać, że w tych metodach są wymagane liczne zbiory wyników.

Niezależnie od przyjętej metody analizy, odpowiednia jakość danych jest kluczowym czynnikiem wpływającym na wynik, a więc i jakość zbudowanego modelu. Przed obliczeniami trzeba wybrać typ modelu, na przykład równanie deterministyczne, lub sieć neuronową, oraz przygotować wyniki tak, aby mogły być one użyteczne, tzn. wykonać preprocessing. Następnie przeprowadza się analizę poprawności i jednoznaczności danych. Zebrane wyniki nie mogą zawierać braków. Trzeba też zbadać występowanie obserwacji nietypowych. Jeżeli zgromadzone wyniki są niekompletne, można uzupełnić brakujące wartości; na przykład zastąpić je średnią, medianą, albo usunąć przypadki, w których występują braki.

Format zgromadzonych danych może także nie odpowiadać wymaganiom zaplanowanej analizy. Dlatego często przekształca się je w zbiory spełniające określone założenia. Tego rodzaju działania mają na celu poprawę jakości modelu oraz skrócenie czasu analizy. Jednym ze sposobów jest normowanie. Stosowanym sposobem normowania szeregów czasowych jest podzielenie wartości aktualnych przez średnią [12, 13]. Tego typu przekształcenia są szczególnie przydatne przy zastosowaniu sieci neuronowych. Sieci neuronowe należą do metod sztucznej inteligencji obliczeniowej. W tej pracy stosowano sztuczne sieci neuronowe.

Drugi etap to budowanie modelu i jego ocena. Testuje się różne modele, na przykład różne sieci neuronowe. Wybiera się najlepszy z nich, najczęściej na podstawie ocen statystycznych. Stosując zbudowane modele zwykle rozwiązuje się dwa rodzaje

Prof. dr hab. inż. Jerzy Straszko, Bartosz Jarosławski – Instytut Chemii i Podstaw Ochrony Środowiska, Politechnika Szczecińska, Al. Piastów 42, 71–065 Szczecin


zadań: bardziej bezpośrednie, którym jest predykcja i ogólniejsze, polegające na odczytywaniu wiedzy. Predykcja dotyczy sytuacji kiedy dysponujemy kompletnymi danymi z przeszłości, a na bieżąco chcemy przewidzieć wartości na podstawie niepełnych danych jakimi dysponujemy. W tym sposobie prognozowania stosuje się regresję i klasyfikację. Szczególnym przypadkiem regresji jest przewidywanie przyszłych wartości szeregu czasowego. Jak wspomniano mierzone na stacjach monitoringu powietrza wartości zmiennych wyznaczają szeregi czasowe.

Odkrywanie wiedzy to wnikliwy opis danych, wskazujący na stru-

ktury, zależności i prawidłowości w nich ukryte. Było to głównym celem tej pracy. Uzyskane metodami inteligencji obliczeniowej wyniki są ważne dla fizyki atmosfery. Mogą być też użyteczne jako istotne uzupełnienie obecnie wykonywanych analiz podczas oceny jakości powietrza.

Dane doświadczalne

Podstawą obliczeń były wyniki pomiarów wykonanych według obowiązujących zasad w okresie wrzesień 2007–luty 2008 r. na stacjach monitoringu powietrza aglomeracji krakowskiej, w szcze-



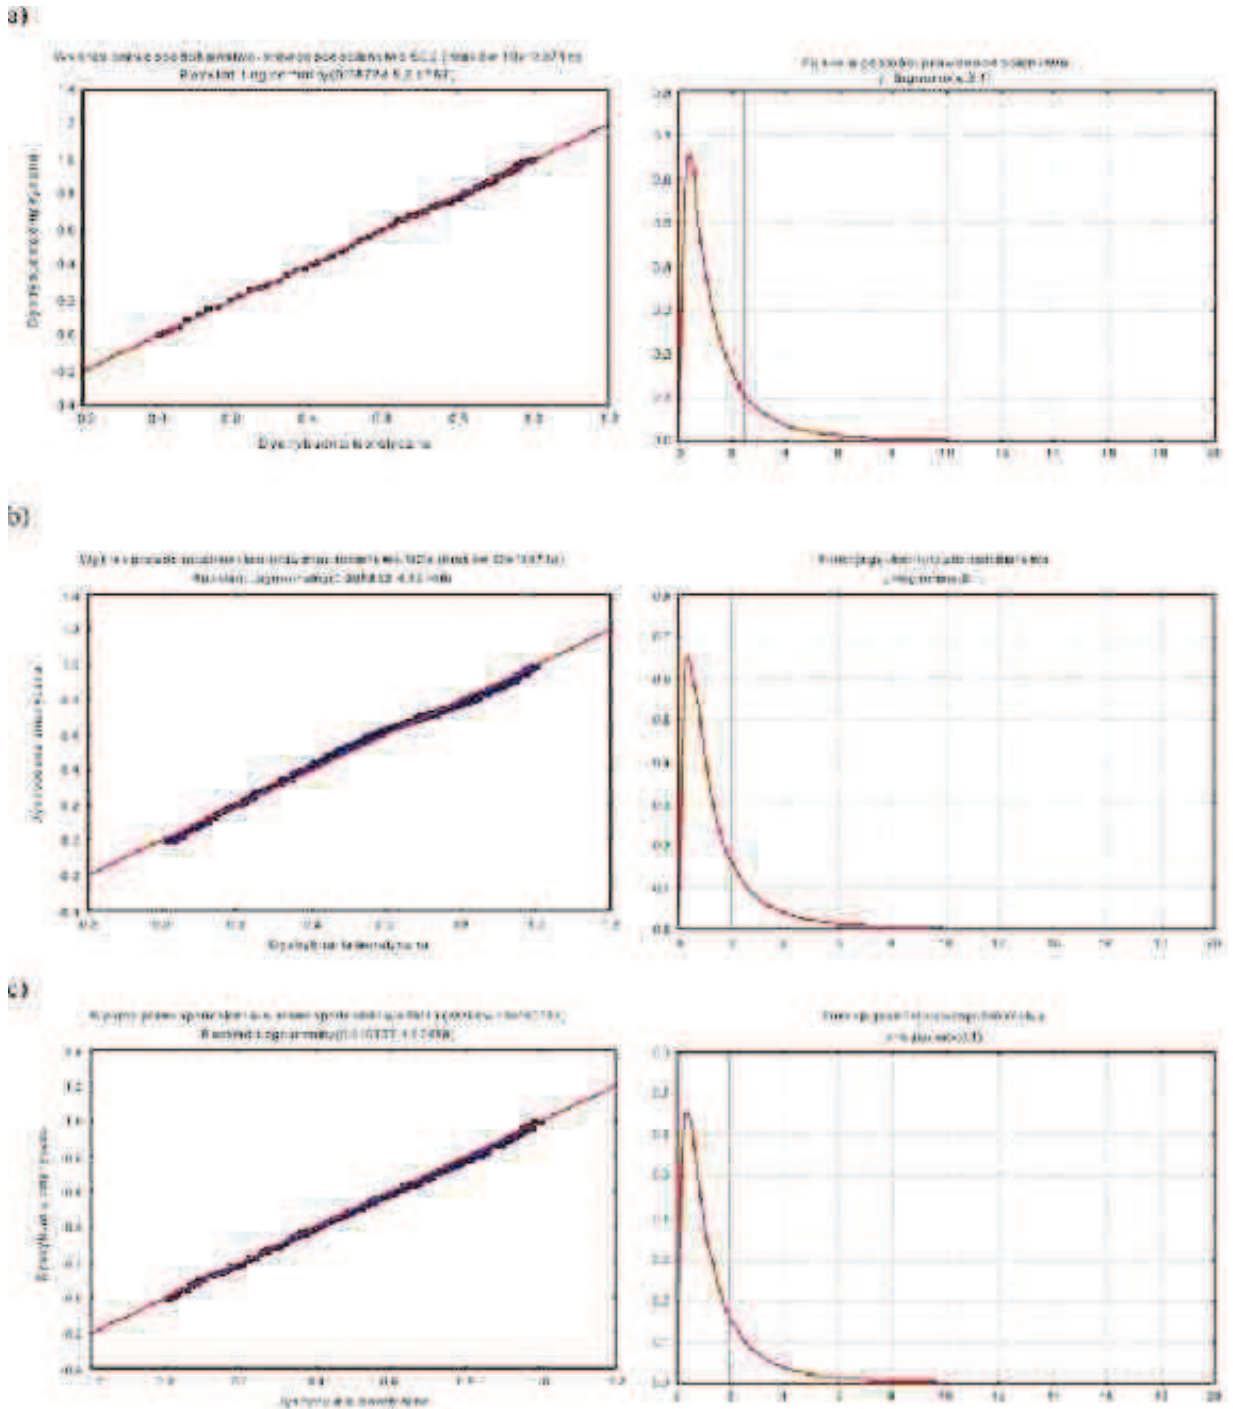
Rys.1. Rozkłady w czasie stężeń zanieczyszczeń i parametrów meteorologicznych. Sacja Kraków–Krowodrza, 2007–2008; a) SO_2 ; b) NO_2 ; c) NO ; d) NO_x ; e) PM_{10} ; f) temperatura; g) prędkość wiatru; h) kierunek wiatru

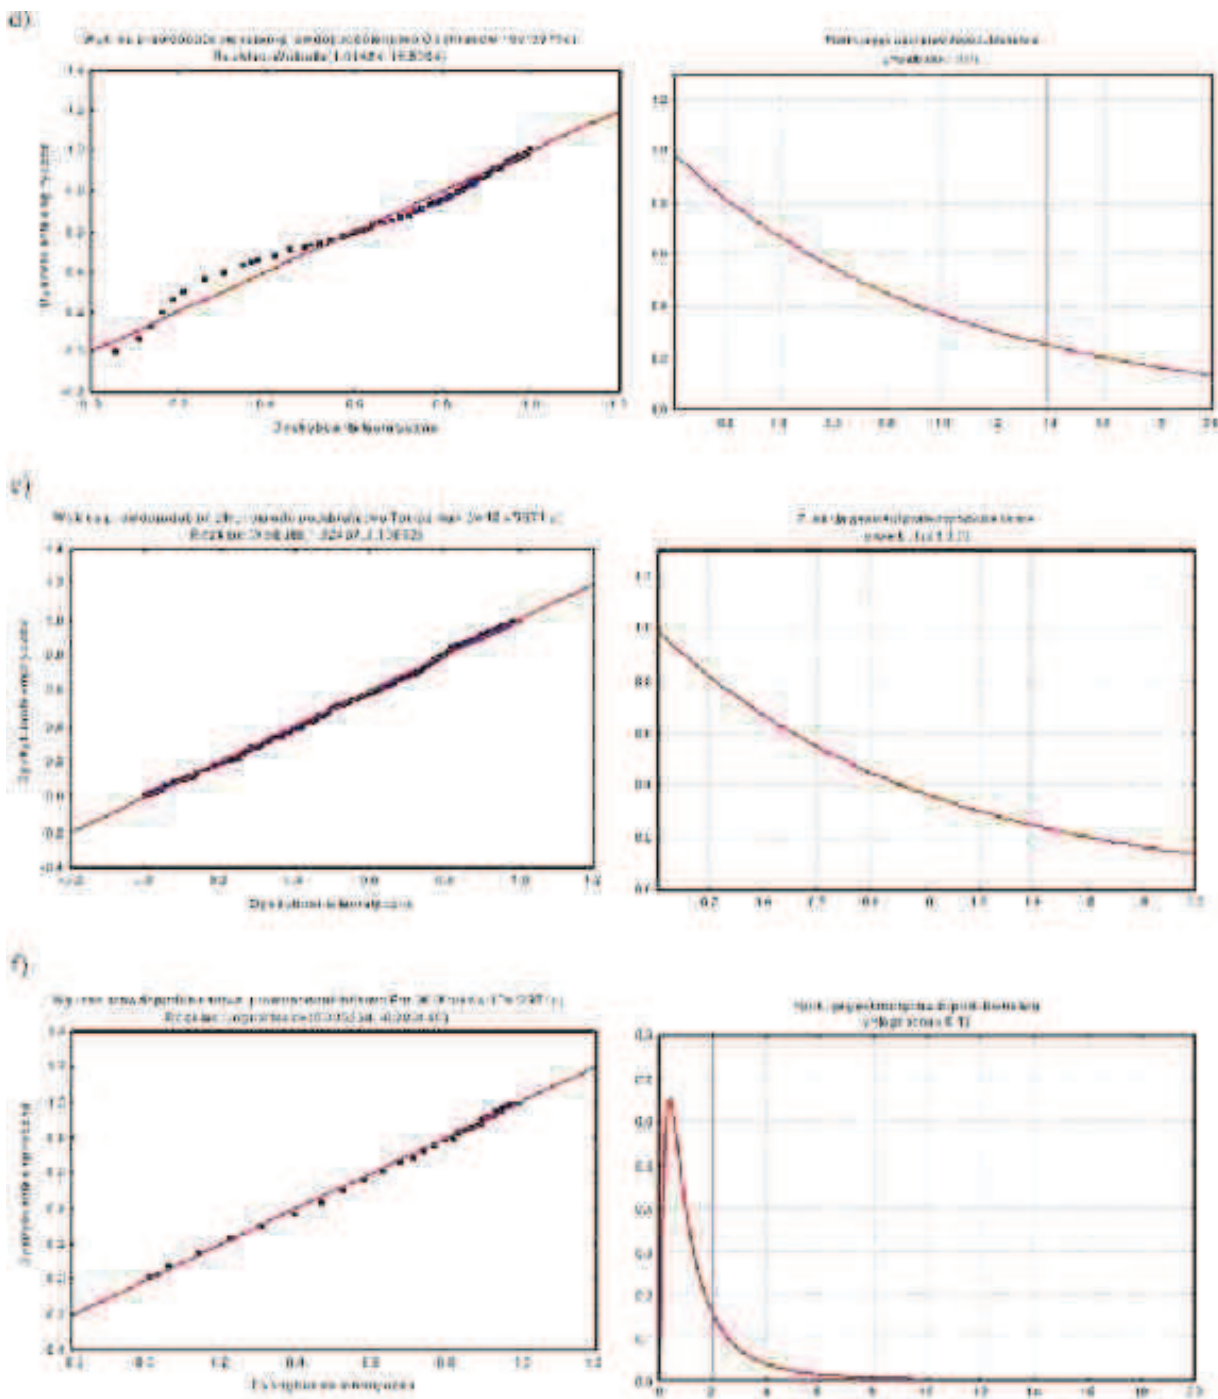
gólności na stacjach: Kraków – Krowodrza, Olkusz, Nowa Huta oraz Trzebinia [45]. Na rysunku 1 pokazano dla przykładu wyniki pomiarów na stacji Kraków – Krowodrza. Widać, że mierzone wielkości wyznaczają szeregi czasowe ze znacznymi wahaniami. Należy podkreślić, że omawiane rezultaty dotyczą głównie sezonu grzewczego, a więc okresu o wysokich poziomach imisji. Podobne zależności otrzymano dla pozostałych stacji.

W tej pracy nie zajmowano się oceną skażenia powietrza według obowiązujących procedur. Celem była analiza danych, metodami sztucznej inteligencji obliczeniowej, wskazująca na struktury, zależności i prawidłowości w nich ukryte. Pierwszym etapem było określenie ich charakterystyk probabilistycznych tradycyjnymi metodami statystycznymi.

Wyznaczenie charakterystyk probabilistycznych opisywanych zmiennych

W pracach [12, 13, 30–35], stosując wartości 30-minutowe wykazano, że mierzone na stacjach monitoringu powietrza wielkości, z dobrym przybliżeniem opisują rozkłady jednowymiarowe co oznacza, że można je traktować jako zmienne losowe z niezależnymi w czasie przyrostami. Obecnie są stosowane wartości godzinne. Należało sprawdzić czy te relacje obowiązują również w tym wypadku. Testowano znane rozkłady jednowymiarowe. Stosowano program komputerowy Statystyka 5. Obliczenia wykonano dla wszystkich stacji. Dla przykładu zamieszczono rezultaty uzyskane dla stacji Kraków–Krowodrza. Na rysunku 2 przedstawiono wykresy prawdopodobieństwo – prawdopodo-





Rys. 2. Wykresy prawdopodobieństwo–prawdopodobieństwo i gęstości prawdopodobieństwa dla wybranych rozkładów. Stacja Kraków–Krowdrza, 2007-2008r. a) SO₂ – lognormalny; b) NO_x – lognormalny; c) PM₁₀ – lognormalny; d) O_# – Weibulla; e) temperatura – Weibulla; f) prędkość wiatru – lognormalny

bieństwo oraz wykresy gęstości prawdopodobieństwa dla wybranych rozkładów. We wszystkich przypadkach otrzymano dobrą dokładność. Rozkłady są asymetryczne co oznacza, że mogły występować znacznie wyższe wartości od średnich.

Widać, że były spełniane różne rozkłady, głównie lognormalny. Oznacza to, że szum zakłócający propagację zanieczyszczeń można traktować jako stacjonarny proces stochastyczny [44]. Teoria tych procesów jest znana. Modele matematyczne mają formę stochastycznych równań różniczkowych. Znane są też metody rozwiązywania tych równań [44].

W wypadku innych stacji, dla tej samej zmiennej, na przykład

stężeń godzinnych SO₂, uzyskiwano albo ten sam rozkład ale z innymi parametrami, albo inny rozkład. Przeprowadzone obliczenia wykazały, że mierzone na stacjach wielkości można traktować jako zmienne losowe o przyrostach niezależnych.

Tradycyjnymi metodami statystycznymi uzyskuje się tylko podstawowe charakterystyki probabilistyczne; określa się typ rozkładu, wartości średnie, wartości minimalne i maksymalne, asymetrię itp. Uzyskane w ten sposób wyniki nie wyrażają dynamiki procesu, tzn. zmian mierzonych wielkości w czasie. Aby te zmiany opisać trzeba było zastosować odpowiednie metody matematyczne.

Analiza szeregów czasowych


Rejestrowane na stacjach monitoringu powietrza wielkości wyznaczają szeregi czasowe. W ten sposób przebiega wiele zjawisk dotyczących zagadnień ekonomicznych, finansowych, technologicznych, przyrodniczych itp. Została opracowana teoria tych procesów i metody aplikacji w postaci programów komputerowych. Są używane metody tradycyjne [46] i sieci neuronowe [6, 8, 12, 13]. Oba te sposoby były stosowane podczas analizy wielkości mierzonych na stacjach monitoringu powietrza. W pracach [12, 13] otrzymano dobrą dokładność oboma metodami. Podczas obliczeń stosowano wartości 30-minutowe. W wypadku wielkości godzinnych częstość próbkowania jest dwukrotnie mniej-

sza. Może to nie wystarczać do uzyskania dobrej dokładności. Wykonano obliczenia dla wszystkich zmiennych. Stosowano program komputerowy Statistica Neural Network. Dla przykładu podano wyniki uzyskane dla SO₂ i temperatury. Architektury zbudowanych sieci pokazano na rysunku 3.

Symbol oznacza typ sieci, a liczba podaje ilość neuronów ukrytych. Ocenę statystyczną tych sieci zamieszczono w tabeli 1.

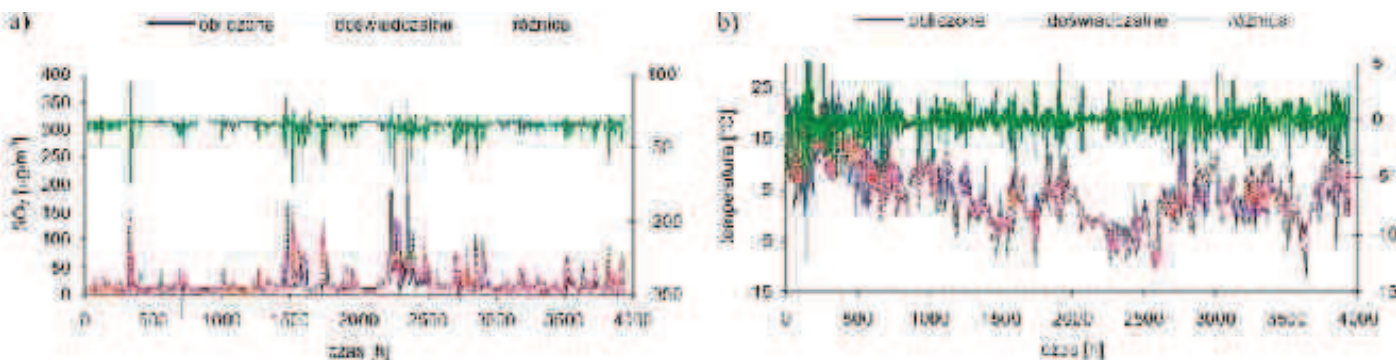
Na rysunku 4 porównano wartości tych zmiennych obliczone i wyznaczone doświadczalnie. Nie otrzymano dobrej dokładności. Powodem niskiej dokładności mogła być niewystarczająca liczba pomiarów. Wniosek ten dotyczy również innych metod analizy szeregów czasowych.

Rys. 3. Architektura zbudowanych sieci;
a) SO₂ – GRNN 1974; b) temperatura – GRNN1961



Tab. 1. Ocena statystyczna zbudowanych sieci

Wyszczególnienie	GRNN 1/1974			GRNN 1/1974		
	Tr. SO ₂	Ve. SO ₂	Te. SO ₂	Tr. T	Ve. T	Te. T
Data Mean	19.2412	19.59918	18.22006	4.13065	4.33249	4.09888
Data S.D.	20.45469	25.30208	20.10494	5.97045	6.1306	5.78076
Error Mean	-1.19525	-1.62165	-1.25033	-0.0127	0.00497	0.02849
Error S.D.	9.630165	14.26751	11.85589	0.84142	0.98146	1.06501
Abs E. Mean	6.369759	6.875387	6.909467	0.57034	0.68176	0.69069
S.D. Ratio	0.470805	0.563887	0.5897	0.14093	0.16009	0.18423
Correlation	0.889246	0.834719	0.814122	0.9901	0.98718	0.98289



Rys. 4. Porównanie wartości obliczonych i wyznaczonych doświadczalnie. Stacja Kraków–Krowodrza; a) SO₂; b) temperatura

Analiza zależności funkcyjnych

Mierzone na stacjach monitoringu powietrza wielkości są zmiennymi losowymi (procesami stochastycznymi). Występują między nimi zależności. Na przykład stężenia zanieczyszczeń zależą od warunków meteorologicznych. Badanie korelacji pomiędzy rejestrowanymi zmiennymi, tzn. odkrywanie wiedzy wskazujące na struktury i prawidłowości ukryte w danych, nazwano analizą funkcjonalną.


Aby przeprowadzić taką analizę metodą sieci neuronowych

należy wyróżnić zmienne określane i zmienne określające. Do zmiennych określających należą: czas, prędkość i kierunek wiatru oraz temperatura. Stężenia zanieczyszczeń, w ogólności trzeba zaliczyć do zmiennych określanych.

Opisując stężenia zanieczyszczeń mierzone na stacjach monitoringu zwykle nie mamy ważnych informacji, takich jak: liczba emitorów rozmieszczonych na rozpatrywanym obszarze, ich charakterystyki techniczne oraz wielkości emisji, które stanowią podstawę strukturalnych modeli transportu atmosferycznego.

Konstruując sposób analizy w tej pracy wykorzystano zasadę redukcji. Polega ona na tym, że niektóre mierzone wielkości mogą uzupełniać brakujące informacje. Na przykład temperatura powietrza jest związana ze spalaniem paliw w celach grzewczych. Może zatem uzupełniać wyniki dotyczące emisji zanieczyszczeń z tych procesów. Należy dodać, że niektóre zanieczyszczenia reagują w powietrzu. Wtedy współzależność ich stężeń jest naturalna. Zależności pomiędzy mierzonymi wielkościami nie są liniowe. Dla takich przypadków nie ma ogólnych metod strukturalnych. Sztuczne sieci neuronowe są wtedy szczególnie przydatne [6, 8.47].

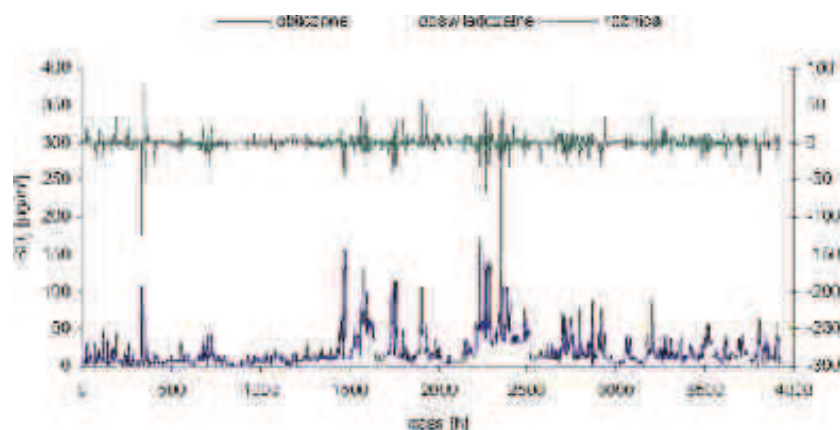
Podczas obliczeń stosowano program komputerowy Statistica Neural Network. Na rysunku 5 pokazano dla przykładu architekturę zbudowanej sieci dla stężeń SO₂ traktowanych jako zmienna opisywana. Ocena statystyczną tej sieci podano w tabeli 2. Natomiast na rysunku 6 porównano stężenia SO₂ obliczone i wyznaczone doświadczalnie. Otrzymana dokładność jest wystarczająca dla przeprowadzenia analizy funkcyjnej. Najpierw oceniono czułość parametryczną. Wyniki podano w tabeli 3. Wiersze oznaczone kolorem czarnym dotyczą zbioru treningowego, a oznaczone kolorem czerwonym zbioru weryfikacyjnego. W obu wypadkach kolejność jest taka sama, co potwierdza wystarczającą dokładność obliczeń.



Rys. 5. Architektura sieci GRNN 7/1961

Tab. 2. Ocena statystyczna sieci GRNN 7/1961

Parametr	Tr. SO ₂	Ve. SO ₂	Te. SO ₂
Data Mean	18,88424	19,54694	18,82977
Data S.D.	20,83346	24,64781	20,05804
Error Mean	-0,05742	0,001546	0,004787
Error S.D.	3,504261	14,18319	10,11346
Abs E. Mean	1,982655	5,902681	5,456609
S.D. Ratio	0,168204	0,575434	0,50421
Correlation	0,98628	0,817896	0,865426



Rys. 6. Porównanie stężeń SO₂ obliczonych i wyznaczonych doświadczalnie. Kraków–Krowodrza, 2007–2008 r.

Największy wpływ na rejestrowane stężenie SO₂ na tej stacji miała temperatura. Jak wspomniano wcześniej jest to związane ze spalaniem paliw. Wyraźna korelacja ze stężeniem PM10 wskazuje na emisję znacznych ilości tych zanieczyszczeń z tych samych źródeł. Potem mamy kierunek wiatru i czas. Niską korelację z NO_x można przypisać znacznemu udziałowi emisji tlenków azotu z innych źródeł, w szczególności transportu samochodowego.

W ten sam sposób wykonano obliczenia dla innych zmiennych. Przedstawiono uzyskane rezultaty. Na rysunku 7 pokazano zależności stężeń wybranych zanieczyszczeń od temperatury.


Dla SO₂, NO_x i PM10 otrzymano podobne wykresy. Maksymalne stężenia tych zanieczyszczeń występowało przy temperaturze bliskiej zeru. Jest to związane ze spalaniem paliw i oznacza, że te zanieczyszczenia, na rozpatrywanym obszarze, pochodzą głównie z tych procesów. Podobne rezultaty otrzymano dla innych stacji. Wskazują one, że przy niskich temperaturach były znacznie gorsze warunki aerosanitarne. W przypadku O₃ jest inaczej. Powyżej 10°C, ze wzrostem temperatury wzrastało stężenie ozonu. W tym wypadku temperatura wskazywała na wzrost promieniowania ultrafioletowego, istotnego przy syntezie O₃. Otrzymane wyniki pokazują, że czasem ta sama zmienna może zawierać różne informacje. Jest to przykład zasady redukcji, stosowanej w tej pracy w celu uzupełnienia brakujących informacji.

Na rysunku 8 przedstawiono zależność stężeń wybranych zanieczyszczeń od prędkości wiatru. Widać, że stężenia SO₂ i PM10 znacznie zależały od prędkości wiatru. Przy prędkościach wiatru mniejszych od 2 m/s stężenia tych zanieczyszczeń były wysokie. Oznacza to, że wtedy były gorsze warunki aerosanitarne. Dla niektórych innych stacji dobre przewietrzanie stref następowało przy prędkościach wiatru większych od 4 m/s. W wypadku O₃ nie stwierdzono wyraźnej zależności stężenia od prędkości wiatru.


Na rysunku 9 pokazano zależności stężeń wybranych zanieczyszczeń od kierunku wiatru.

Tab. 3. Ocena czułości parametrycznej


Parametr	NO _x	O ₃	PM10	VW	KW	T	CZAS
Rank	6	5	2	7	3	1	4
Error	7,4490	7,9540	12,8039	7,36316	11,8056	13,0330	11,4031
Ratio	2,125	2,2701	3,6542	2,10145	3,3693	3,7196	3,25448
Rank	6	5	2	7	3	1	4
Error	15,020	16,5853	18,3986	14,3516	17,8553	18,6927	17,6666
Ratio	1,0596	1,1699	1,2978	1,01239	1,25954	1,31862	1,2462




Rys. 7. Zależności stężeń zanieczyszczeń od temperatury. Stacja Kraków–Krowodrza 2007–2008 r.; a) SO₂, b) PM



Rys. 8. Zależności stężeń zanieczyszczeń od prędkości wiatru. Stacja Kraków–Krowodrza 2007–2008 r.; a) SO₂, b) PM10, c) O₃



Rys. 9. Zależności stężeń zanieczyszczeń od kierunku wiatru. Stacja Kraków–Krowodrza 2007v2008 r.; a) SO₂, b) NO_x c)PM₁₀, d) O₃



Rys. 10. Współzależność pomiędzy stężeniami wybranych zanieczyszczeń. Stacja Kraków–Krowodrza, 2007–2008 r.; a) SO₂–O₃; b) NO_x–O₃; c) SO₂–PM₁₀; d) SO₂–NO_x; e) NO_x–PM₁₀

W przypadku tej stacji stężenia zanieczyszczeń znacznie zależały od kierunku wiatru. Wskazują one, że duże źródła emisji tych zanieczyszczeń, w stosunku do stacji, były położone na północy. W wypadku innych stacji, na przykład Nowa Huta, nie zaobserwowano wyraźnej zależności emisji od kierunku wiatru. Można to wyjaśnić następująco. Jeżeli źródła emisji są rozmieszczone równomiernie wokół stacji, wtedy kierunek wiatru nie wpływa w sposób istotny na poziom emisji. Natomiast kiedy źródła emisji są ułożone w jednym miejscu, wtedy warunki aerodynamiczne zależą od kierunku wiatru.

Na rysunku 10 pokazano ustalone korelacje pomiędzy stężeniami wybranych zanieczyszczeń. Rysunki 10a i 10b wskazują na istotną współzależność pomiędzy stężeniami SO_2 , NO_x i stężeniem ozonu. Przy wysokich stężeniach SO_2 , NO_x występowały niskie stężenia O_3 . Oznacza to, że ozon był zużywany w reakcjach utleniania SO_2 i NO . Podobne zależności otrzymano dla pozostałych stacji. Z rysunku 10c wynika, że przy wyższych stężeniach PM_{10} występowały również wyższe stężenie SO_2 . Oznacza to, że w aglomeracji krakowskiej oba te zanieczyszczenia, w dużej mierze, były emitowane z tych samych źródeł. Nie stwierdzono (rysunek 10d) wyraźnej korelacji pomiędzy stężeniami SO_2 i NO_x , co oznacza, że znaczne ilości tlenków azotu były emitowane z innych źródeł. Natomiast rysunek 10e pokazuje widoczną korelację pomiędzy stężeniami NO_x i PM_{10} . Taka korelacja jest zasadna. Tlenki azotu, podobnie jak PM_{10} , są emitowane z procesów spalania paliw oraz transportu samochodowego. Przy większym ruchu samochodowym więcej jest emitowanych tlenków azotu. Większy ruch samochodowy powoduje także większe pylenie.

Podsumowanie i wnioski

Przedstawiona praca nie dotyczy bezpośrednio oceny jakości powietrza. Jej celem była analiza struktury wyników pomiarów rejestrowanych na stacjach monitoringu powietrza metodami zaliczanymi do sztucznej inteligencji obliczeniowej [8, 40–43]. Podstawą analizy były wyniki pomiarów wykonanych według obowiązujących zasad w okresie wrzesień 2007–luty 2008 r. na stacjach monitoringu powietrza aglomeracji krakowskiej, w szczególności na stacjach: Kraków–Krowodrza, Olkusz, Nowa Huta oraz Trzebinia [45].

Pierwszym etapem było wyznaczenie charakterystyk probabilistycznych. Obliczenia wykonano dla wszystkich stacji. Dla przykładu podano wyniki otrzymane dla stacji Kraków–Krowodrza. Wykazano, że z dobrym przybliżeniem były spełniane rozkłady jedowymiarowe, a najczęściej rozkład lognormalny. Rozkład ten jest charakterystyczny dla stacjonarnych procesów stochastycznych [44]. Teoria tych procesów jest znana.

Zbadano współzależność pomiędzy rozpatrywanymi zmiennymi. Porównano szeregi czasowe wielkości unormowanych, otrzymanych przez podzielenie obserwowanych wartości zmiennych przez ich wartości średnie. Stwierdzono, że nie występowały zależności liniowe pomiędzy rejestrowanymi zmiennymi zarówno na tej samej stacji jak i na różnych stacjach.

Przeprowadzono analizę funkcyjną. Stosowano metodę sieci neuronowych. Uzyskano dobrą dokładność (współczynnik korelacji 0,82–0,99). Oznacza to, że z dobrą dokładnością ustalono opisane współzależności pomiędzy rozpatrywanymi zmiennymi. Określono czułość parametryczną dla zmiennych opisujących.

Wyniki zestawiono w tabelach, a na wykresach pokazano zależności zmiennych opisujących od zmiennych opisanych. Wyniki można podsumować następująco. Ranking parametrów opisujących był różny dla różnych zmiennych opisanych jednej stacji. Był także inny dla tej samej zmiennej rejestrowanej na różnych stacjach.

Temperatura jest ważną zmienną opisującą. Wnosi inne informacje niż jako wielkość fizyczna. W przypadku SO_2 na przykład wskazuje na spalanie paliw w celach grzewczych, a w przypadku ozonu na intensywność promieniowania ultrafioletowego decydującego o tworzeniu tego związku.

Imisje rejestrowane na stacjach znacznie zależały od prędkości wiatru. Były wysokie przy prędkościach wiatru mniejszych od 2–4 m/s. Taką zależność otrzymano dla wszystkich rozpatrywanych stacji. Wpływ kierunku wiatru przejawiał się różnie. Na przykład w wypadku stacji Kraków–Krowodrza imisja znacznie zależała od kierunku wiatru, a w wypadku stacji Nowa Huta wpływ ten był niewielki. Jest to związane z rozmieszczeniem emitorów w stosunku do tych stacji.

Ustalona współzależność pomiędzy stężeniami zanieczyszczeń informuje o źródłach emisji i przemianach zachodzących w powietrzu z ich udziałem.

W krajowych bazach danych monitoringu powietrza zgromadzono obszerne, wartościowe wyniki. Nie zostały one w pełni wykorzystane w standardowym systemie oceny jakości powietrza. Przeprowadzone obliczenia wykazały, że stosując metody inteligencji obliczeniowej można uzyskać istotne informacje o procesach generujących imisje zanieczyszczeń i określić ich zależność od parametrów. Metody te wzbogacają tradycyjny system oceny jakości powietrza w regionach przemysłowych. Dostarczają też informacji użytecznych przy teoretycznym opisie transportu atmosferycznego.

LITERATURA

- [1] Juda J., Chróściel S.: Ochrona powietrza atmosferycznego, WNT, Warszawa 1974
- [2] Zonnatti P.: Air pollution modeling. Theories computational method and available software. Van Nostrand Reinhal, New York 1974
- [3] Pasquill F., Smith F. B.: Atmospheric diffusion, Holsed Press, John Wiley and Sons, New York 1986
- [4] Bartnicki J., Heavy Metal Eulerian Transport Model – HMET. Model Description and Results, DNMI Research Raport No 65, June, Oslo 1998
- [5] Chróściel S., Jagunowicz A., Jaworski W., Juda J., Nowicki M., Warchołowski A.: Obliczenia stanu zanieczyszczenia atmosfery według Wytycznych Inżynierów i Techników Sanitarnych, Warszawa 1981
- [6] Skrzypski J.: Analiza i modelowanie pól imisji powietrza w dużych miastach, Wyd. PAN Oddział w Łodzi, Łódź 2002
- [7] Zwoździak J.: Metody prognozy i analizy stężeń zanieczyszczeń w powietrzu w regionie Czarnego Trójkąta., Oficyna Wydawnicza Politechniki Wrocławskiej, Wrocław 2002
- [8] Kamiński W., Strumiło P., Toczek E.: Zastosowanie systemów sztucznej inteligencji obliczeniowej w rozwiązywaniu wybranych problemów ochrony atmosfery, PAN w Łodzi, Łódź 2005
- [9] Paulo L.A.: Analiza pól imisji zespołów źródeł punktowych, praca doktorska, Politechnika Szczecińska, Szczecin 1996
- [10] Szalińska W.: Zastosowanie hybrydowego modelu deterministyczno-statystycznego do oceny i prognozy stężeń zanieczyszczeń powietrza atmosferycznego, praca doktorska, Politechnika Wrocławska, Wrocław 2002
- [11] Michalczyk K.: Transport gazowych zanieczyszczeń w powietrzu – symulacje numeryczne w skali lokalnej, praca doktorska, Politechnika Lubelska, Lublin 2003
- [12] Dziubakiewicz D.: Dynamika skażenia powietrza atmosferycznego, praca doktorska, Politechnika Szczecińska, Szczecin 2004
- [13] Bykowszczenko N.: Identyfikacja modeli skażenia powietrza w regionach przemysłowych, praca doktorska, Politechnika Szczecińska, Szczecin 2007

- [14] Van Rneek L.J., Van Jaarsfeld H., De Leeuw F.: A Lagrangian model for the real time simulation of atmospheric transport and dispersion of accidentally released materials, *Air pollution modelling and its applications VII*, New York & London 1988
- [15] Straszko J., Paulo L.A., Witkowski A.: Models of distribution of pollution in the air, *Env. Protec. Eng.*, 1–2, 71, 1996
- [16] Pyta H., Zwoździak J.: Hybrydowe modele rozkładu stężeń zanieczyszczeń powietrza, *Arch. Ochr. Środ.*, 23 (3/4), 59, 1997
- [17] Christensen J. H.: The Danish Eulerian hemispheric model – a three-dimensional air pollution model used for the Arctic, *Atmos. Environ.*, 31, 4169, 1997
- [18] Straszko J., Paulo L. A., Witkowski A.: Modele rozprzestrzeniania zanieczyszczeń w atmosferze, *Szczecińskie Roczniki Naukowe*, XI (2/1), 119, 1997
- [19] Kamiński W., Skrzypski J.: The analysis of air pollution as a tool for environmental management in city, *Environmental Engineering and Management*, WIT Press, Boston, Southampton 1998
- [20] Galperin M. V., Sofiev M.A.: The long-range transport of ammonia and ammonium in the north – hemisphere, *Atmos. Environ.*, 32 (3), 373, 1998
- [21] Zwoździak J., Szalińska W.: Zastosowanie modeli hybrydowych do oceny i prognozy rozkładu stężeń dwutlenku siarki w powietrzu, *Materiały konferencyjne, POL-EMIS*, 99, Wyd. PZITS, Szklarska Poręba, 13, 1999
- [22] Straszko J.: Stochastyczne modele rozprzestrzeniania zanieczyszczeń w powietrzu, *Inż. Chem. Proc.*, 21, 393, 2000
- [23] Skrzypski J.: Model predykcji stężeń wybranych zanieczyszczeń powietrza w dużych miastach (na przykładzie Łodzi). IV Konferencja „Problemy ochrony powietrza w aglomeracjach miejsko-przemysłowych”, *Materiały konferencyjne*, 2001
- [24] Straszko J., Dziubakiewicz D.: Ocena skażenia atmosfery w regionach na podstawie analizy zmienności pól emisji zanieczyszczeń, *Problem Ekologii*, 1(7), 21, 2003
- [25] Madany A., Bartochowska M.: Przegląd polskich modeli rozprzestrzeniania zanieczyszczeń atmosferycznych, *prace Naukowe Politechniki Warszawskiej* 19, 1995
- [26] Łobacki L.: Wskazówki metodyczne dotyczące modelowania matematycznego w systemie zarządzania jakością powietrza, *Instytut Systemów Inżynierii Środowiska, Politechnika Warszawska*, Warszawa 2003
- [27] Chrościel S., Jaguszewicz A., Jaworski W., Juda J., Nowicki M., Warchałowski A.: Wytyczne obliczania stanu powietrza atmosferycznego, *MAGT i OŚ*, Warszawa., 1981/83
- [28] Nowicki M.: Parametry empiryczne w modelach dyfuzji zanieczyszczeń w atmosferze, *Ochrona atmosfery, Zeszyt problemowy nr 451/XI*, 84, 1984
- [29] Wolanowska A., Paterkowski W., Straszko J.: Ocena wybranych modeli rozprzestrzeniania zanieczyszczeń w powietrzu, *Ochrona Powietrza*, 2, 40, 1997
- [30] Larsen R.: Analizing Air Pollutant Concentration and Dosage Data, *Air Pollut. Control ASS*, 17, 85, 1967
- [31] Larsen R.: New Mathematical Model of Air Pollutant Concentration Averaging Time and Frequency, *Air Pollut. Control ASS*, 19, 24, 1969
- [32] Taylor J., et al.: Statistical Modelling of Restricted Pollutant Data Sets to Assess Compliance with Air Quality Criteria, *Environmental Monitoring and Assessment*, 9, 29, 1987
- [33] Davies T. D.: Regression and stochastic models for air pollution – I review comments and suggestion, *Atmos. Environ.*, 28, 2801, 1994
- [34] Zwoździak J., et al.: Pomiar i obróbka danych jako źródło informacji o stanie zanieczyszczenia powietrza, w pracy zbiorowej pt. *Człowiek Środowisko i Zarządzanie*, Wrocław 2002
- [35] Zwoździak J., et al.: Deterministyczno-statystyczne metody analizy zanieczyszczeń w receptorze, w pracy zbiorowej pt. *Człowiek-Środowisko-Zagrożenie*, Wrocław 2002
- [36] Straszko J., Dziubakiewicz D.: Sieci neuronowe w ocenie jakości powietrza, *Ochrona Powietrza i Problemy Odpadów*, 197 (3), 87, 2000
- [37] Machoy Z., Straszko J., Dziedzicko V., Gutowska I.: Estimation of Influence of Industrial Emissions on Fluorides Accumulation in Deers Jaws by Neural Network, *Environ. Sci.*, 4(9), 289, 2002
- [38] Straszko J., Dziubakiewicz D.: Sieci neuronowe w ocenie jakości powietrza, *Ochrona Powietrza i Problemy Odpadów*, 34, 3, 2000
- [39] Gajda J. B.: Prognozowanie i symulacja a decyzje gospodarcze, *Wydawnictwo CH. Beck*, Warszawa 2001
- [40] Valnus A., Demski T.: Data mining – inteligencja biznesowa, *Magazyn Przemysłowy*, 3 (56), 38, 2004
- [41] Berry M.J.A., Lonoff G.: Data mining techniques for marketing, sales and customer support, *Wiley and Sons*, New York 1997
- [42] Data Mining – metody i przykłady, *Stat-Soft Polska*, 2002
- [43] Gruszyński M.: Modele i prognozy zmiennych jakościowych w finansach i bankowości, *Oficyna Wydawnicza Szkoły Głównej Handlowej*, Warszawa 2002
- [44] Wojewódzki Inspektorat Ochrony Środowiska w Krakowie, <http://www.krakow.pios.gov.pl>
- [45] Sobczak K.: Stochastyczne równania różniczkowe, *WNT*, Warszawa 1996
- [46] Kolenda K., Kolenda M.: Analiza i prognozowanie szeregów czasowych, *Agencja Wydawnicza Placet*, Warszawa 1999
- [47] Osowski S.: Sieci neuronowe w ujęciu algorytmicznym, *WNT*, Warszawa 1996

Kalendarium ekologa

LISTOPAD

- 3 listopada **Święto Myśliwych**
- 3-4 listopada **Światowy Dzień bez Papierosa**
- 18 listopada **Światowy Dzień Walki z Tytoniem**
- 25 listopada **Światowy Dzień Rzucania Palenia**
- 25 listopada **Dzień Bez Futra**
- 28 listopada **Międzynarodowy Dzień bez Kupowania**
- 29 listopada **Dzień ogłoszenia św. Franciszka patronem ekologów**

GRUDZIEŃ

- 22 grudnia **Pierwszy Dzień Zimy**
- 22 grudnia **Międzynarodowy Dzień Różnorodności Biologicznej (ONZ)**