

PROGNOZOWANIE KLAS STANU JAKOŚCI POWIETRZA JAKO INSTRUMENT ZARZĄDZANIA BEZPIECZEŃSTWEM EKOLOGICZNYM W AGLOMERACJACH MIEJSKO-PRZEMYSŁOWYCH

Jerzy SKRZYPSKI, Emilia JACH-SZAKIEL
Politechnika Łódzka, ul. Wólczańska 213, 90-924 Łódź
skrzypsk@wipos.p.lodz.pl

STRESZCZENIE

Testowano możliwości rozszerzenia instrumentarium zarządzania jakością powietrza w dużych miastach. Działania skoncentrowano na opracowaniu neuronowych modeli predykcji klas stanu jakości powietrza (w aspekcie stężeń pyłu PM_{10}). Prognozowano klasę jakości powietrza na dzień następny w odniesieniu do średnich oraz maksymalnych stężeń dobowych. Testowano modele typu MLP) oraz RBF). Uzyskano satysfakcjonujące wyniki. W optymalnie skonstruowanych modelach odsetek prognoz błędnych (w seriach testowych) wynosił zaledwie 1,9% w przypadku prognozowania średnich stężeń dobowych oraz 9,2% w odniesieniu do prognoz dobowych stężeń maksymalnych.

1. Wprowadzenie

Pogorszony stan jakości powietrza przyczynia się do pogorszenia jakości życia mieszkańców dużych i uprzemysłowionych miast. Zanieczyszczone powietrze jest więc jednym z ważnych czynników zwiększających ryzyko zdrowotne. Wysokie poziomy stężeń zanieczyszczeń mogą incydentalnie (smog) generować sytuacje groźne dla zdrowia, a nawet życia mieszkańców. Niekorzystne warunki aerosanitarne są konsekwencją funkcjonowania przemysłu, komunikacji i transportu (zwłaszcza samochodowego) oraz gospodarki komunalnej (dostawy ciepła i energii elektrycznej na potrzeby ogrzewnictwa, klimatyzacji oraz sprzętu RTV i AGD). W kształtowaniu wysokich stężeń zanieczyszczeń powietrza sprzyjają niektóre typy warunków meteorologicznych i typy cyrkulacji atmosferycznej a także cechy i osobliwości charakterystyczne dla wszystkich dużych miast.

W instrumentarium zarządzania ryzykiem zdrowotnym istotną rolę spełniają prognozy stanów jakości powietrza. Prognozy te umożliwiają ogłaszanie ostrzeżeń i alarmów oraz wprowadzania ograniczeń emisji zanieczyszczeń powietrza. W prognozowaniu jakości powietrza nie zawsze potrzebne jest określenie dokładnej wartości stężenia. Do ostrzegania ludności przed zagrożeniami z tytułu wysokich stężeń zanieczyszczeń powietrza wystarczy określenie przedziału (klasy) przewidywanych wartości stężeń.

Predykcja stanu jakości powietrza w miastach jest zadaniem trudnym. Procesy formowania się pól koncentracji zanieczyszczeń powietrza przebiegają bowiem pod wpływem licznych i zróżnicowanych czynników oraz uwarunkowań. Z reguły czynniki determinujące przebieg procesów formowania się pól stężeń zanieczyszczeń powietrza w dużych miastach nie są dostatecznie rozpoznane, zarówno w aspekcie dnia bieżącego jak i dnia następnego. Przede wszystkim dotyczy to niedostatków w zakresie rozpoznania procesów emisji zanieczyszczeń, zwłaszcza w obszarach, na których funkcjonują liczne źródła stacjonarne i ruchome. Każde źródło ma odmienne warunki i parametry wyrzutu gazów odlotowych. Równocześnie każde źródło charakteryzuje się indywidualną zmiennością wielkości emisji poszczególnych zanieczyszczeń powietrza. Dodatkowym utrudnieniem prognozowania stanu aerosanitarne w miastach są deformacje pól meteorologicznych pod wpływem struktur

urbanistycznych, antropogenicznej emisji ciepła oraz procesów kształtowania się miejskiej wyspy ciepła i bryzy miejskiej. Należy także uwzględnić, że procesy kształtujące warunki meteorologiczne i pola stężeń zanieczyszczeń powietrza przebiegają dynamicznie a wzajemne oddziaływania poszczególnych czynników są skomplikowane i nie mają charakteru liniowego. Ze względu na niedostatki w parametryzacji czynników i uwarunkowań stosowanie prognostycznych modeli numerycznych i deterministycznych wymaga wprowadzenia rozmaitych uproszczeń i współczynników. Mimo tego efekty uzyskiwane przy zastosowaniu modeli strukturalnych często nie są zadawalające.

Sprawdzonym narzędziem opisu i predykcji pól stężeń zanieczyszczeń powietrza w miastach są sztuczne sieci neuronowe (SSN) [1-3]. SSN mają zdolność do uogólniania zależności oraz minimalizowania wpływu czynników drugorzędowych. Pozwala to na wykorzystanie niekompletnych, obarczonych błędami pomiarowymi danych. SSN znalazły szczególne zastosowanie do prognozowania poziomu zanieczyszczeń powietrza w miastach.

W niniejszej pracy prezentowane są wyniki badań, których celem było zwiększenie efektywności instrumentarium zarządzania bezpieczeństwem ekologicznym w dużych, uprzemysłowionych miastach poprzez opracowanie neuronowych modeli predykcji klas stanu jakości powietrza.

2. Obszar i zakres badań

Poligonem badawczym do testowania neuronowych modeli prognostycznych było miasto Łódź (około 800 tys. mieszkańców). W pracy wykorzystano wyniki pomiarów wykonanych przez WIOŚ w Łodzi w latach 2004-2007. Stacje pomiarowe funkcjonują w systemie zapewnienia jakości. Pomiary wykonywane są w układzie ciągłego monitoringu automatycznego. Wyniki są uśredniane w przedziale 1 godziny, co umożliwia rozpoznanie dobowego rytmu zmian warunków aerosanitarnych i wskazanie podokresu, w którym stan zanieczyszczenia powietrza jest relatywnie najgorszy. Wszystkie wyniki pomiarów podlegają procedurom weryfikacji.

W pracy wykorzystano dane z monitoringu stężeń zanieczyszczeń powietrza z półroczy chłodnych (od XI-III), kiedy stężenia te, a więc i ryzyko zdrowotne, są największe. Modele predykcji testowano w odniesieniu do pyłu PM_{10} . Podstawą takiego wyboru były częste przekroczenia wartości standardów jakości powietrza. Naruszanie standardów jakości powietrza następuje w Łodzi głównie w centrum miasta, gdzie funkcjonuje multum indywidualnych pieców węglowych. Jednocześnie w centrum miasta następuje pylenie wtórne, generowane przez intensywny ruch pojazdów. Z tych powodów do badań wykorzystano dane pomiarowe ze stacji monitoringu zlokalizowanej w ścisłym centrum Łodzi miasta (ul. Zachodnia). Wykorzystano również dane z automatycznego monitoringu warunków meteorologicznych, które w istotnym stopniu uczestniczą w kształtowaniu stężeń.

3. Modele predykcji

Testowano możliwość wykorzystania dwóch rodzajów sztucznych sieci neuronowych, MLP i RBF, do prognozowania klas warunków aerosanitarnych w odniesieniu do wartości średnich dobowych, a także dobowych wartości maksymalnych. W obliczeniach uwzględniono dane tylko z miesięcy chłodnych (łącznie 544 dni), kiedy koncentracja pyłu w powietrzu jest relatywnie duża. Dane wejściowe to wartości stężeń PM_{10} w powietrzu oraz parametry meteorologiczne – temperatury ekstremalne, opady, promieniowanie słoneczne, wiatr i pionowe ruchy powietrza.

Struktura modeli była wstępnie optymalizowana w aspektach liczby neuronów ukrytych (w modelu MLP) i liczby centrów (w modelu RBF), proporcji pomiędzy wielkością zbioru treningowego do zbioru testowego oraz minimalizacji wektora wejściowego, poprzez zastosowanie Analizy Składowych Głównych (PCA). Ostatecznie zastosowano 3-warstwowy model MLP z 4 neuronami ukrytymi, a także sieć RBF z 4 centrami. Dla obu testowanych sieci neuronowych wektorami wejściowymi były dane o koncentracji pyłu PM₁₀ oraz wartości parametrów meteorologicznych (bez transformacji danych metodą PCA). Dla każdego rodzaju sieci wykonano 2 warianty obliczeń. Warianty te różniły się zakresem danych wejściowych w aspekcie stężeń PM₁₀ w dniu poprzednim. Przeprowadzona analiza autokorelacji wykazała bowiem, że stężenia w dniu „n+1” istotnie zależą (średnio w 67%) od wartości stężeń z dnia „n”. Na wyjściu z sieci neuronowej uzyskiwano prognozowaną na dzień „n+1” klasę jakości powietrza (w aspekcie maksymalnych i średnich stężeń dobowych).

Dane pomiarowe stężeń PM₁₀ zostały pogrupowane w 5 przedziałów klasowych, w zależności od wartości stężenia (odrębnie dla stężeń dobowych maksymalnych oraz średnich). Szerokość klas została zadeklarowana, przy czym uwzględniono obowiązujące standardy jakości powietrza i krotność tych standardów. Rezultaty predykcji klas jakości powietrza oceniano poprzez ocenę wielkości różnicy liczby klas pomiędzy stanem rzeczywistym a stanem prognozowanym. Brak różnicy to prognoza dobra. Różnicę o dwie klasy traktowano jako prognozę błędną, różnicę o jedną klasę traktowano jako wynik akceptowany.

4. Ocena wyników modelowania

Szczegółowe wyniki neuronowego prognozowania klas jakości powietrza w Łodzi zaprezentowano w tabelach 1 i 2. Uzyskane wyniki należy uznać jako wysoce satysfakcjonujące. W optymalnie skonstruowanych modelach odsetek prognoz błędnych w seriach testowych wynosił zaledwie 1,9%, w przypadku prognozowania średnich stężeń dobowych, oraz 9,2% w odniesieniu do prognoz dobowych stężeń maksymalnych.

Tabela 1. Wyniki predykcji klas jakości powietrza w aspekcie średnich dobowych stężeń pyłu PM₁₀ w powietrzu w Łodzi w sezonie chłodnym (XI-III) w latach 2004-2007

Warianty obliczeń	Odsetek wyników [%]					
	Dobrych		Akceptowanych		Błędnych	
	Trening	Test	Trening	Test	Trening	Test
MLP-1	61,6	58,3	37,0	38,0	1,4	3,7
MLP-2	52,9	48,1	38,6	44,4	8,5	7,5
RBF-1	51,3	54,6	45,5	43,5	3,2	1,9
RBF-2	57,2	53,7	37,9	42,6	4,9	3,7

Przeciętne z różnych modeli i wariantów wartości odsetek błędnych prognoz klas jakości powietrza w aspekcie średniodobowych stężeń PM₁₀ wyniosły 4,5% w serii treningowej oraz 4,2% w serii testowej. Przy prognozowaniu klas jakości powietrza w aspekcie dobowych maksymalnych stężeń PM₁₀ przeciętny odsetek błędów wynosił 4,0% w seriach treningowych i 9,9% w seriach testowych.

Przeprowadzona optymalizacja sieci neuronowych umożliwiła budowę modeli o strukturze oszczędnie rozbudowanej. Do minimum ograniczono liczebność wektorów wejściowych oraz liczbę warstw i neuronów a także liczbę wag oraz centrów. Dzięki temu

procedury sieci neuronowych przebiegały szybko i efektywnie. Dowodem tej efektywności są małe różnice pomiędzy wynikami predykcji uzyskiwanymi w seriach treningowych i testowych. Wyniki modelowania potwierdzają wysoką przydatność metod sztucznej inteligencji do oceny i predykcji jakości powietrza w miastach.

Tabela 2. Wyniki predykcji klas jakości powietrza w aspekcie maksymalnych dobowych stężeń pyłu PM₁₀ w powietrzu w Łodzi w sezonie chłodnym (XI-III) w latach 2004-2007

Warianty obliczeń	Odsetek wyników [%]					
	Dobrych		Akceptowanych		Błędnych	
	Trening	Test	Trening	Test	Trening	Test
MLP-1	61,6	58,3	35,4	31,5	3,0	10,2
MLP-2	59,8	58,3	37,5	31,5	2,7	10,2
RBF-1	56,3	57,4	39,1	32,4	4,6	10,2
RBF-2	54,9	56,5	39,5	34,3	5,6	<u>9,2</u>

5. Podsumowanie i wnioski

W niniejszym opracowaniu zastosowano modele neuronowe do predykcji klas jakości powietrza w miastach. Opracowano i testowano 2 rodzaje ANN: MLP type and RBF type. W konstruowaniu modeli neuronowych wykorzystano doświadczenia własne w zakresie optymalizacji struktury sieci oraz struktury wektora wejściowego. Modele neuronowe umożliwiają uzyskiwanie trafnych prognoz warunków aerosanitarnych, zarówno w odniesieniu do stężeń średniodobowych jak i maksymalnych stężeń dobowych (przy małej ilości przypadków prognoz błędnych). Modele neuronowe mogą więc stanowić część instrumentarium zarządzania bezpieczeństwem ekologicznym w dużych miastach.

Modelowanie neuronowe ma jednak wady. Modele neuronowe można stosować tylko w miastach o rozbudowanym systemie monitoringu środowiska. Dla każdej stacji pomiarowej należy przeprowadzić od początku pracochłonne procedury trenowania sieci neuronowej. Należy także przeprowadzać procedury optymalizacji architektury sieci neuronowych, dążąc do minimalizacji ilości wektorów wejściowych, warstw, neuronów, centrów i wag.

Praca naukowa finansowana ze środków na naukę w latach 2008-2010 jako projekt badawczy

Literatura

1. Lu W.Z., Wang W.J., Wang X.K., Yan S.H., Lam J.C.: Potential assessment of neural network model with PCA/RBF approach for forecasting pollutants trends in Mong Kok urban air, Hong Kong, Environmental Research, 2004, 97, 79-87.
2. Niska H., Hiltunen T., Karppinen A., Ruuskanen J., Kolehmainen M.: Evolving the neural network model for forecasting air pollution time series, Engineering Applications of Artificial Intelligence, 2004, 17, 159-167.
3. Kukkonen M, Niska H., Dorling S., Chatterton T., Foxall R., Cawley G.: Extensive evaluation of neural network models for prediction of NO₂ and PM₁₀ concentrations, compared with deterministic modeling and measurements in central Helsinki, Atmospheric Environment, 2003, 37, 4539-4550.