

Walidacja i optymalizacja modelu jakości powietrza ATMO-Street za pomocą wielkoskalowego zbioru danych pomiarowych nad Warszawą

Raport z realizacji projektu funduszu badań własnych
Nr 4/07/2023

dr inż. Anahita Sattari
Zespół Centralnej Bazy Emisyjnej - KOBiZE

01.10.2023 – 31.03.2025

Streszczenie

Praca ta początkowo rozpoczęła się jako podprojekt w ramach projektu Comobility, uruchomiony w maju 2022 roku podczas stażu w instytucie Vito w Mol, Belgia. Celem było przeprowadzenie wysokorozdzielczego (do 10 m) modelowania jakości powietrza nad Warszawą z wykorzystaniem łańcucha modeli ATMO-Street opracowanego w Vito. Istotnym elementem projektu było po raz pierwszy połączenie modelu GEM-AQ jako komponentu tła stężeń w ramach tego łańcucha. Modelowanie koncentrowało się na zanieczyszczeniach NO₂, PM₁₀ oraz PM_{2.5}, a jego wyniki były oceniane na podstawie danych ze stacji pomiarowych w różnych scenariuszach, z naciskiem na analizę zdolności modelu do odwzorowania gradientów stężeń w skali lokalnej. W miarę postępu prac ujawnił się istotny problem ograniczonej liczby stacji referencyjnych – szczególnie stacji komunikacyjnych – co stanowiło wyzwanie dla wiarygodnej walidacji modelu. W związku z tym zaistniała potrzeba włączenia pomiarów z czujników na dużą skalę, aby zwiększyć dokładność oceny wyników modelowania. Dodatkowo, pierwsze wyniki modelowe wskazały na znaczące niepewności w danych emisyjnych, które wymagały dalszej analizy i poprawy. Kontynuacja tej współpracy była możliwa dzięki wsparciu z Funduszu Badań Własnych. W tej fazie projektu skupiono się na analizie różnych scenariuszy emisji w celu poprawy skuteczności modelu w odwzorowywaniu stężeń PM₁₀ i PM_{2.5} w Warszawie. W celu lepszej oceny wyników modelu, dane z sieci czujników Airly zostały zintegrowane z danymi ze stacji referencyjnych GIOŚ, co umożliwiło bardziej kompleksową walidację rezultatów modelowania.

Podziękowania

Realizacja tego projektu nie byłaby możliwa bez wsparcia i współpracy wielu osób oraz instytucji.

Przede wszystkim pragnę wyrazić moją najgłębszą wdzięczność dr. Stijnowi Janssenowi, dr. Hansowi Hooyberghsowi oraz Lisie Blyth z Instytutu VITO w Belgii. Ich wiedza, wsparcie oraz cenne spostrzeżenia odegrały kluczową rolę w rozwoju tego badania i znacząco poszerzyły moją wiedzę z zakresu modelowania jakości powietrza.

Chciałabym również serdecznie podziękować moim koleżankom i kolegom z Instytutu Ochrony Środowiska – Państwowego Instytutu Badawczego, a w szczególności prof. Joannie Strużewskiej oraz Aleksandrowi Norowskiemu z Zakładu Modelowania Atmosfery i Klimatu za ich nieoceniony wkład i współpracę w trakcie trwania projektu.

Szczególne podziękowania kieruję do zespołu Centralnej Bazy Emisyjnej: dr inż Lecha Gawucia, dr inż Karola Szymankiewicza oraz dr. Iwa Augustyńskiego za ich nieustające wsparcie techniczne w przygotowaniu danych wejściowych do modelowania. Jestem również bardzo wdzięczna Jadwidze Maciejewskiej i Annie Paczosie za ich nieocenioną pomoc na każdym etapie realizacji tego projektu.

Spis treści

1	Wstęp	1
2	Warszawa	3
3	Metodologia i dane wejściowe do modelu	3
3.1	Łańcuch modeli ATMO-Street	3
3.2	Dane emisyjne	5
3.2.1	Scenariusze emisji	8
3.3	Dane dotyczące stężeń tła	10
3.4	Inne dane wejściowe	11
3.5	Dane pomiarowe	13
3.5.1	Analiza czujników	17
3.6	Miary błędów statystycznych	21
4	Wyniki	22
4.1	Walidacja wyników modelu dla PM10 i PM2.5	22
4.2	Miesięczne profile czasowe	26
4.3	Analiza scenariuszy i statystyczne miary błędów	28
4.3.1	PM2.5	29
4.3.2	PM10	33
4.4	Wpływ czynników meteorologicznych	36
5	Podsumowanie	37
6	Osiągnięcia w projekcie	39
	Literatura	41

1 Wstęp

Szczególnie w gęsto zaludnionych miastach, takich jak Warszawa, jednym z najpoważniejszych problemów środowiskowych pozostaje zanieczyszczenie powietrza. Do najistotniejszych zanieczyszczeń należą pyły zawieszone (PM_{2.5} i PM₁₀), pochodzące z różnych źródeł, takich jak ogrzewanie, emisje z transportu oraz działalność przemysłowa. Ekspozycja na te zanieczyszczenia wiąże się z poważnymi skutkami zdrowotnymi, w tym chorobami układu oddechowego i krążenia, a także z szeroko pojętymi skutkami ekologicznymi [24, 15].

PM₁₀, powszechny zanieczyszczający składnik powietrza, pochodzi z emisji komunikacyjnych, działalności przemysłowej, pyłu drogowego oraz naturalnych źródeł, takich jak sól morską czy pożary lasów. Krótkotrwała ekspozycja na PM₁₀ może zaostrzać choroby układu oddechowego, takie jak astma, oraz prowadzić do wzrostu liczby hospitalizacji z powodu chorób układu oddechowego i krążenia. Długotrwałe narażenie wiąże się z pogorszeniem funkcji płuc, rozwojem przewlekłych chorób oddechowych oraz zwiększonym ryzykiem przedwczesnej śmierci [2, 26].

Z kolei cząstki PM_{2.5} są na tyle małe, że mogą ominąć naturalne mechanizmy obronne organizmu, przenikając głęboko do płuc, a nawet do krwiobiegu. Cząstki te powstają głównie w wyniku procesów spalania, w tym emisji z pojazdów, przemysłu i ogrzewania budynków [31]. PM_{2.5} uważany jest za najbardziej szkodliwy zanieczyszczający składnik powietrza, ponieważ może oddziaływać niemal na każdy narząd w ciele człowieka. Badania epidemiologiczne szacują, że drobne pyły zawieszone przyczyniają się rocznie do około 4 milionów zgonów na świecie z powodu chorób sercowo-płucnych, nowotworów i innych schorzeń [32]. W samej Europie długotrwała ekspozycja na PM_{2.5} może skracać średnią długość życia nawet o osiem miesięcy [34].

Ograniczenie emisji PM₁₀ i PM_{2.5} poprzez lepszą kontrolę emisji i odpowiednie planowanie przestrzenne może znacząco zmniejszyć liczbę hospitalizacji i przedwczesnych zgonów związanych z zanieczyszczeniem powietrza [8, 19, 33].

Aby sprostać tym wyzwaniom, w niniejszym badaniu wykorzystano łańcuch modeli ATMO-Street, integrujący wiele komponentów w celu symulacji jakości powietrza w miastach z wysoką rozdzielczością przestrzenną. Model łączy GEM-AQ do modelowania tła, IFDM do emisji lokalnych oraz OSPM dla efektów w kanionach ulicznych, uwzględniając wzajemne oddziaływania źródeł regionalnych i lokalnych [30].

Jednakże dokładne modelowanie wymaga precyzyjnych inwentaryzacji emisji [4] oraz

walidacji z wykorzystaniem wiarygodnych danych pomiarowych [21, 10]. Badania wykazały, że rozbieżności w danych emisyjnych – szczególnie dotyczących ogrzewania indywidualnego i resuspensji pyłu drogowego – mogą prowadzić do znaczących błędów w oszacowaniach stężeń zanieczyszczeń [9].

Ostatnie postępy w technologii sensorów zrewolucjonizowały również monitoring jakości powietrza, oferując tańsze alternatywy dla tradycyjnych urządzeń referencyjnych. Mimo dużego potencjału, czujniki niskokosztowe często charakteryzują się wyższą niepewnością, co wymaga ich kalibracji oraz integracji z modelami w celu poprawy dokładności [28, 27]. Głównym celem niniejszego badania jest opracowanie i ocena solidnych, skalowalnych ram modelowania jakości powietrza w miastach, które wykorzystują zarówno zaktualizowane inwentaryzacje emisji, jak i zintegrowane dane pomiarowe z tanich czujników oraz stacji referencyjnych. Na przykładzie Warszawy, jako reprezentatywnego obszaru miejskiego, dążymy do odpowiedzi na następujące pytania naukowe:

- W jaki sposób uwzględnienie wysokorozdzielczych, aktualnych inwentaryzacji emisji — szczególnie dotyczących ogrzewania indywidualnego oraz wtórnej emisji pyłu z dróg — wpływa na dokładność i rozdzielczość przestrzenną modelowania stężeń PM₁₀ i PM_{2.5} w środowisku miejskim?
- W jakim stopniu skalibrowane sieci tanich czujników, połączone z regulacyjnymi stacjami referencyjnymi, mogą poprawić walidację i wiarygodność modeli jakości powietrza w miastach, zwłaszcza w obszarach o ograniczonej tradycyjnej infrastrukturze pomiarowej?
- Jakie są kluczowe ograniczenia i niepewności obecnych podejść modelowych, szczególnie w okresach występowania epizodów wysokich stężeń zanieczyszczeń lub zmiennych warunków meteorologicznych, oraz w jaki sposób można je ograniczyć dzięki lepszej integracji danych i strategiom kalibracyjnym?

Odpowiadając na powyższe pytania, badanie ma na celu dostarczenie praktycznych wniosków dla zarządzania jakością powietrza w miastach, wsparcie projektowania przyszłych sieci monitorujących oraz wniesienie uniwersalnej metodyki, możliwej do zastosowania w innych miastach borykających się z podobnymi wyzwaniami związanymi z zanieczyszczeniem powietrza.

2 Warszawa

Warszawa jest stolicą Polski oraz jej największym miastem, liczącym około 1.8 miliona mieszkańców (26 listopada 2025: www.um.warszawa.pl). Miasto jest częścią województwa mazowieckiego, położonego w centralno-wschodniej części Polski. Województwo mazowieckie znajduje się w strefie klimatu umiarkowanego. Ze względu na położenie w centrum Europy, obszar ten charakteryzuje się klimatem przejściowym strefy średnich szerokości geograficznych. Mazowsze leży w strefie dominujących wiatrów z kierunków zachodniego i południowo-zachodniego. Średnia roczna prędkość wiatru w tym regionie wynosiła od 12 do 13 m/s, natomiast średnia roczna temperatura mieściła się w zakresie od 9 do 10°C w roku 2022, który jest rokiem odniesienia w niniejszym badaniu [17].

Główne źródła zanieczyszczenia powietrza na Mazowszu to emisje antropogeniczne pochodzące z sektora komunalno-bytowego, transportu oraz działalności przemysłowej. W Warszawie znaczący udział w całkowitych emisjach mają emisje związane z ruchem pojazdów i zużyciem paliw [16]. Warszawa od początku lat 90. XX wieku doświadcza dynamicznego wzrostu gospodarczego, co znacząco wpłynęło na strukturę floty pojazdów. Według danych Głównego Urzędu Statystycznego, całkowita liczba zarejestrowanych pojazdów w Warszawie wzrosła o prawie 58% w latach 1995–2011, osiągając około 1.2 miliona [13].

3 Metodologia i dane wejściowe do modelu

3.1 Łańcuch modeli ATMO-Street

ATMO-Street to narzędzie do modelowania jakości powietrza o wysokiej rozdzielczości, działające na poziomie ulicznym [11], z przestrzenną rozdzielczością 10 metrów. Flamandzka Agencja Środowiska (Vlaamse Milieumaatschappij, VMM) wykorzystuje model ATMO-Street do oceny zanieczyszczenia powietrza na poziomie ulicznym we Flandrii – gęsto zaludnionym regionie Europy Północno-Zachodniej. Ponadto ATMO-Street stanowi podstawowe narzędzie do planowania, oceny skutków regionalnych i lokalnych inicjatyw dotyczących jakości powietrza oraz analiz wpływu zanieczyszczeń na zdrowie we Flandrii.

W niniejszym badaniu łańcuch modeli ATMO-Street został wykorzystany do symulacji rocznych stężeń PM_{2.5} i PM₁₀ z wysoką rozdzielczością przestrzenną w środowisku miejskim. Łańcuch modeli został zaprojektowany specjalnie do oceny jakości powietrza

w skali lokalnej, poprzez integrację wkładów zarówno ze źródeł regionalnych, jak i lokalnych [23]. Proces modelowania rozpoczyna się od oszacowania regionalnych stężeń tła, które stanowią bazę, na którą nakładane są lokalne wpływy. Oryginalnie, do tego celu w łańcuchu modeli ATMO-Street wykorzystywano model RIO, oparty na regresji z uwzględnieniem użytkowania terenu [14]; jednak w niniejszym badaniu zastosowano zamiast niego model transportu chemicznego GEM-AQ [18]. GEM-AQ symuluje tło zanieczyszczeń powietrza, uwzględniając transport atmosferyczny na dużą skalę, warunki meteorologiczne oraz regionalne źródła emisji, dostarczając w ten sposób fizycznie uzasadnionych szacunków stężeń tła.

W celu odwzorowania emisji w skali lokalnej, model ATMO-Street integruje model IFDM (Immission Frequency Distribution Model), dwugaussowski model rozprzestrzeniania plumu, opracowany dla zastosowań lokalnych. IFDM symuluje rozprzestrzenianie się nierozkładających się zanieczyszczeń pochodzących ze źródeł liniowych (np. ruch drogowy) oraz punktowych (np. ogrzewanie budynków) [22, 23]. Model wykorzystuje gęstą siatkę receptorów, zazwyczaj rozmieszczonych co 20 metrów wzdłuż dróg, co umożliwia szczegółowe odwzorowanie gradientów stężeń zanieczyszczeń, zwłaszcza w złożonym środowisku miejskim.

W środowisku miejskim tzw. kaniony uliczne — wąskie ulice ograniczone z obu stron gęstą zabudową — mogą znacząco wpływać na rozprzestrzenianie się zanieczyszczeń. Aby uwzględnić te efekty, do łańcucha modeli włączono Operational Street Pollution Model (OSPM) [3]. OSPM łączy model plumu dla bezpośrednich emisji pojazdów z modelem pudełkowym, reprezentującym recyrkulację zanieczyszczeń wewnątrz kanionu ulicznego. W tym badaniu OSPM został zastosowany na odcinkach dróg, przy których budynki znajdują się zazwyczaj w odległości mniejszej niż 50 metrów od osi jezdni. W łańcuchu modelowym zastosowano korektę podwójnego zliczania [22], aby uniknąć nakładania się wkładów ze źródeł lokalnych (ATMO-Street) i regionalnego tła (GEM-AQ).

Stężenia obliczone przez modele IFDM i OSPM w punktach receptorowych są następnie przetwarzane i przekształcane w siatkę w trójstopniowym procesie post-processingu. Najpierw wyniki IFDM są siatkowane przy użyciu triangulacji Delaunay’a, co pozwala uzyskać mapę stężeń dla otwartych przestrzeni ulicznych. Następnie wyniki OSPM są siatkowane za pomocą interpolacji metodą najbliższego sąsiada. W ostatnim kroku obie mapy są scalane w jedną mapę o rozdzielczości 10 metrów. W obszarach z przylegającą zabudową wykorzystywane są wyniki OSPM, a w pozostałych — IFDM.

Łańcuch modeli oblicza godzinowe stężenia zanieczyszczeń w wielu nieregularnie

rozmieszczonych receptorach, koncentrując się na źródłach liniowych, które są następnie interpolowane do spójnej siatki o rozdzielczości 10 metrów. Te przestrzenne dane wyjściowe o wysokiej rozdzielczości umożliwiają szczegółową ocenę poziomów zanieczyszczeń, zwłaszcza w obszarach o złożonej morfologii miejskiej.

W celu oceny sprawności modelu, symulowane stężenia z łańcucha modeli ATMO-Street (GEM-AQ, IFDM i OSPM) zostały porównane z danymi pomiarowymi z dziewięciu stacji monitoringu jakości powietrza zlokalizowanych w obrębie analizowanego obszaru.

3.2 Dane emisyjne

W niniejszym badaniu wykorzystano emisje z sektora komunalno-bytowego pochodzące z krajowej inwentaryzacji emisji, opracowanej i utrzymywanej przez Zespół Zarządzania Krajową Bazą – Centrum Bazy Emisyjnej w KOBiZE. Szacowanie emisji z sektora komunalno-bytowego opierało się na szerokim zakresie parametrów wejściowych, w tym charakterystyce budynków, takich jak lokalizacja, powierzchnia, liczba kondygnacji, liczba stopniodni grzewczych (HDD), rodzaje paliw (gaz, drewno, węgiel i olej opałowy), zużycie gazu na potrzeby ogrzewania, wiek budynku (uwzględniający stan izolacji), konfiguracja sieci ciepłowniczych oraz dostęp do tych sieci. Rozdzielczość przestrzenna danych wejściowych była zróżnicowana i zależała od charakteru danego parametru.

Aby zapewnić wysoką dokładność, każdemu punktowi danych przypisano odpowiadający mu budynek na podstawie precyzyjnych współrzędnych geograficznych. W oparciu o to podejście oddolne emisje z sektora komunalno-bytowego zostały obliczone indywidualnie dla każdego budynku w obszarze badań [7]. Dane o emisjach z sektora komunalno-bytowego, pochodzące z dużego zbioru danych obejmującego 228,272 punktowe źródła emisji, zostały następnie przetworzone na potrzeby modelowania.

Emisje z transportu zostały oszacowane na podstawie danych GPS pochodzących z aplikacji nawigacyjnej "Yanosik", która dostarcza szczegółowych informacji o liczbie użytkowników i średnich prędkościach na wszystkich drogach w analizowanym obszarze. Obliczenia emisji oparto na zależnych od prędkości wskaźnikach emisji z bazy COPERT, a strukturę floty przypisano zgodnie z klasą drogi określoną w bazie OpenStreetMap (OSM). Ponieważ dane z Yanosika nie odzwierciedlają dokładnie całkowitego natężenia ruchu, zastosowano współczynnik skalujący – obliczony jako średni stosunek danych o ruchu z modelu miasta stołecznego Warszawy do liczby użytkowników Yanosika na wybranych odcinkach dróg.

Dla głównych dróg dane o ruchu z modelu miejskiego przecięto z siatką 500-metrową. Wybrano punkty w pobliżu autostrad i dróg ekspresowych, a następnie dokonano interpolacji natężenia ruchu oraz składu floty. Wartości te przypisano do segmentów drogowych z bazy OSM w celu utworzenia szczegółowej sieci drogowej. Dla pozostałych dróg dane o natężeniu ruchu zostały podzielone na decyle według intensywności. Każdy decyl przetworzono oddzielnie w celu interpolacji natężeń ruchu i składu floty. Dane z Yanosika dostosowano do struktury i intensywności modelu ruchu miasta (<https://www.cupt.gov.pl/>).

Ostatecznie wszystkie dane drogowe zostały zintegrowane w celu uzyskania dokładnego oszacowania emisji. Obliczenia emisji obejmowały zarówno emisje spalinowe, jak i niespalinowe, jednak nie uwzględniały emisji z wtórnego unoszenia pyłu drogowego. Wcześniejsze badanie [30] wykazało niedoszacowanie stężeń PM10, szczególnie na stacjach monitorujących ruch uliczny. Poprawa wyników modelu nastąpiła po uwzględnieniu emisji wtórnego unoszenia pyłu drogowego. Emisje te zostały obliczone oddzielnie przy użyciu modelu VEIN (Vehicular Emissions INventories) [12], z zastosowaniem wskaźników emisji z dokumentu AP-42 Section 13.2.1 dla dróg utwardzonych ([EPA - AP-42 Section 13.2.1 Paved Roads](#)).

Stwierdzono, że emisja pyłu z dróg utwardzonych różni się w zależności od tak zwanego "silt loading"¹ występującego na powierzchni drogi, a także od średniej masy pojazdów poruszających się po drodze. Termin Silt loading (sL) odnosi się do masy materiału równej lub mniejszej niż 75 mikrometrów [µm] średnicy fizycznej na jednostkę powierzchni drogi. Współczynniki "silt loading" zaczerpnięto z dokumentacji AP42. Ilość emisji pyłów w wyniku unosu wtórnego związanego z ruchem pojazdów po drodze o nawierzchni suchej można oszacować korzystając ze wzoru:

$$E = k \left(\frac{sL}{2} \right)^{0.65} \left(\frac{W}{3} \right)^{1.5} \quad (1)$$

E = współczynnik emisji cząstek stałych (o jednostkach odpowiadających jednostkom k)

k = mnożnik wielkości cząstek dla zakresu wielkości cząstek dla PM10 k=0.62 a dla PM2.5

k= 0.15

sL = Silt Loading (g/m^2)

W = średnia masa pojazdów poruszających się po drodze (tony)

Przetworzone emisje komunikacyjne zostały uwzględnione w łańcuchu modelowania jako

¹Jest to pył, namul znajdujący się na drodze, który podczas ruchu pojazdów jest wzburzany


źródła liniowe rozmieszczone wzdłuż 409,697 odcinków dróg. Źródła te obejmowały zarówno bezpośrednie emisje z ruchu drogowego, jak i dodatkowe emisje pyłu wtórnie unoszonego z nawierzchni drogowej. Zakładając, że roczne (lub inne długoterminowe) średnie emisje z unosu wtórnego są odwrotnie proporcjonalne do częstotliwości mierzalnych opadów (>0.254 mm), równanie 1 zostaje zmodyfikowane w następujący sposób.

$$E = k \left(\frac{sL}{2} \right)^{0.65} \left(\frac{W}{3} \right)^{1.5} \left(1 - \frac{P}{4N} \right) \quad (2)$$

P = liczba "mokrych" dni z opadem co najmniej 0.254 mm na dobę w okresie uśredniania


N = liczba dni w okresie uśredniania (np. 365 w przypadku roku, 91 w przypadku sezonu, 30 w przypadku miesiąca)

Przestrzenny rozkład emisji PM_{2.5} i PM₁₀ ze źródeł liniowych (transport oraz wtórna emisja pyłu drogowego) oraz ze źródeł punktowych (ogrzewanie indywidualne) został przedstawiony odpowiednio na Rysunkach 1 i 2, dostarczając cennych informacji na temat ich rozprzestrzenienia na obszarze miasta stołecznego Warszawy oraz w sąsiednich rejonach objętych badaniem.




Rysunek 1: Przestrzenny rozkład (a) PM₁₀ oraz (b) PM_{2.5} (kg/rok) w obszarze badawczym z sektora transportu drogowego (ruch drogowy + resuspensja pyłu drogowego)

Emisje PM10 z sektora komunalno-bytowego-Base



(a)

Emisje PM2.5 z sektora komunalno-bytowego-Base



(b)

Rysunek 2: Przestrzenny rozkład (a) PM10 oraz (b) PM2.5 (kg/rok) w obszarze badawczym z sektora komunalno-bytowego

3.2.1 Scenariusze emisji

W badaniu początkowo wykorzystano emisje z krajowego inwentarza jako podstawę do stworzenia scenariusza bazowego modelowania. Jednak szczegółowa analiza rozkładu stężeń PM10 i PM2.5 ujawniła lokalne rozbieżności między modelowanymi a obserwowanymi punktami wysokiego zanieczyszczenia. Skłoniło to do dokładnej rewizji danych emisyjnych, szczególnie w sektorze komunalno-bytowym – głównego źródła pyłu zawieszonego w regionie.

Nasza analiza wykazała istotne nieścisłości w założeniach pierwotnego inwentarza dotyczących typów paliw grzewczych. Nieaktualne lub niepełne dane prowadziły do błędnej klasyfikacji, np. niedoszacowania spalania węgla i drewna oraz przeszacowania wykorzystania gazu, jak również do przestrzennych nieprawidłowości w alokacji emisji. Aby temu zaradzić, wprowadzono dane z Centralnej Ewidencji Emisyjności Budynków (CEEB) – rejestrowanej bazy danych, w której właściciele budynków mają ustawowy obowiązek corocznego zgłaszania głównego źródła ogrzewania.

Zbiór danych CEEB znacząco poprawił dokładność emisji z sektora komunalno-bytowego, umożliwiając precyzyjniejsze oszacowanie zużycia poszczególnych paliw i ograniczając niedoszacowanie zużycia drewna, węgla oraz gazu dzięki obowiązkowi raportowania. Proces aktualizacji danych doprowadził do średniego zmniejszenia emisji PM10 i PM2.5 o 22% w obszarach o najwyższym zanieczyszczeniu, głównie poprzez korektę zawyżonych wskaźników wykorzystania paliw niskoemisyjnych w pierwotnym inwentarzu.


Początkowe wyniki modelowania systematycznie niedoszacowywały obserwowanych stężeń PM10 w miesiącach suchych, szczególnie w lokalizacjach o dużym natężeniu ruchu. Rozbieżności te sugerowały zbyt niską reprezentację procesu wtórnej emisji pyłu drogowego – zjawiska silnie zależnego od sezonowych opadów atmosferycznych.

Ze względu na brak lokalnych danych obserwacyjnych dotyczących "silt loading" na polskich drogach, zastosowano podejście kalibracyjne, aby lepiej dopasować sezonowe wzorce PM10 do obserwowanych szczytów. Emisje wtórne zwiększono o 17% zarówno dla PM10, jak i PM2.5, modyfikując współczynniki obciążenia pyłem w czynnikach emisyjnych AP-42 13.2.1. Wartości tych współczynników dla poszczególnych scenariuszy przedstawiono w Tabeli 1. Emisje z transportu – obejmujące zarówno źródła spalinowe, jak i bezspalinowe – pozostały na podobnym poziomie w obu scenariuszach.


Rysunek 3 przedstawia różnicę w całkowitych rocznych emisjach (kg/rok) PM10 i PM2.5 z sektora transportu – uwzględniając emisje spalinowe, bezspalinowe i wtórne – pomiędzy scenariuszami Bazowym i Zmodyfikowanym. Analogicznie, Rysunek 4 prezentuje różnicę w całkowitych rocznych emisjach (kg/rok) PM10 i PM2.5 z sektora ogrzewania indywidualnego pomiędzy scenariuszami Bazowym i Zmodyfikowanym. Oba rysunki przedstawiają dane w siatce o rozdzielczości 500×500 metrów w celu efektywnej wizualizacji przestrzennego rozkładu emisji.

Tabela 1: Wartości "silt loading" przyjęte w scenariuszach Base i Revised do obliczania emisji wtórnej z pyłu drogowego w modelu VEIN.

Silt loading (g/m^2)	Scenariusz Base	Scenariusz Revised
sL1 (ADT <500)	1	1.1
sL2 (500 <ADT <5000)	0.4	0.5
sL3 (5000 <ADT <10000)	0.3	0.4
sL4 (ADT >10000)	0.03	0.03



Rysunek 3: Różnica emisji (a) PM10 oraz (b) PM2.5 (kg/rok) z sektora transportowego (ruch drogowy + resuspensja pyłu drogowego) pomiędzy scenariuszami Revised a Base




Rysunek 4: Różnica emisji (a) PM10 oraz (b) PM2.5 (kg/rok) z sektora komunalno-bytowego pomiędzy scenariuszami Revised a Base

3.3 Dane dotyczące stężeń tła

Stężenia tła zostały zasymulowane za pomocą modelu GEM-AQ – internetowego modelu jakości powietrza, który umożliwia zintegrowane podejście do modelowania składników meteorologicznych i jakości powietrza w ramach jednego systemu atmosferycznego [18]. Model GEM-AQ generował godzinowe stężenia PM2.5 i PM10 na oryginalnej siatce obliczeniowej o rozdzielczości 2.5 km (0.025 stopnia). Emisje ze wszystkich sektorów SNAP


— w tym SNAP1 (produkcja i dystrybucja energii), SNAP2 (spalanie nieprzemysłowe), SNAP3 (spalanie w przemyśle), SNAP4 (procesy produkcyjne), SNAP5 (hałdy), SNAP7 (transport drogowy), SNAP8 (inne pojazdy), SNAP10 (rolnictwo) oraz SNAP11 (grunty) — zostały uwzględnione w modelu tła stężeń, aby zapewnić kompleksowe odwzorowanie źródeł antropogenicznych. Dane te pochodziły z corocznej oceny Zespół Zarządzania Krową Bazą oraz z inwentaryzacji EMEP z 2022 roku dla krajów sąsiednich. Przestrzenny rozkład rocznych średnich stężeń tła PM10 i PM2.5 został przedstawiony na rysunku 5.



Rysunek 5: Średnie roczne stężenia tła (a) PM10 oraz (b) PM2.5 ($\mu\text{g}/\text{m}^3$) uzyskane z modelu GEM-AQ

3.4 Inne dane wejściowe

Dane dotyczące budynków zostały pozyskane z Głównego Urzędu Geodezji i Kartografii (GUGiK) jako baza danych obiektów topograficznych. Baza Danych Obiektów Topograficznych (BDOT10k) to wektorowa baza danych zawierająca przestrzenne położenie obiektów topograficznych wraz z podstawowym opisem ich właściwości. Baza danych raportuje zarówno właściwości przestrzenne (współrzędne, wysokość), cechy budynku (liczbę kondygnacji), jak i atrybuty identyfikacyjne (warstwa/ID) dla każdego budynku. Zawartość oraz poziom szczegółowości bazy BDOT10k odpowiadają tradycyjnej mapie topograficznej w skali 1:10 000 (26 listopada 2025: <https://mapy.geoportal.gov.pl>). Mapę rozmieszczenia przestrzennego budynków przedstawiono na rysunku 6.




Rysunek 6: Buildings distribution in the domain of the model

Dane meteorologiczne (temperatura, prędkość i kierunek wiatru) pochodzą z modelu GEM-AQ dla roku 2022.

Współczynniki zmienności czasowej dla sektora transportowego wykorzystane w niniejszej pracy zostały obliczone specjalnie dla Warszawy na podstawie danych pozyskanych z aplikacji Yanosik (dane GPS).

Schemat blokowy ilustrujący proces modelowania w łańcuchu modelowym ATMO-Street został przedstawiony na Rysunku 7.



Rysunek 7: Schemat blokowy ilustrujący proces modelowania w łańcuchu modelowym ATMO-Street

3.5 Dane pomiarowe

Dane pomiarowe dotyczące PM_{2.5} i PM₁₀ zostały pozyskane z dziewięciu stacji referencyjnych prowadzonych przez Główny Inspektorat Ochrony Środowiska (GIOŚ) oraz z danych sensorowych udostępnionych przez firmę Airly (26 listopada 2025: <https://airly.org/map/pl/>), zebranych z 31 różnych lokalizacji w obrębie analizowanego obszaru badawczego.

Firma Airly zastosowała dwa główne typy czujników do tych pomiarów (26 listopada 2025: <https://airly.org/>):


- Airly Pure: Skoncentrowany na pomiarze pyłów zawieszonych (PM₁, PM_{2.5}, PM₁₀) oraz parametrów takich jak temperatura, wilgotność i ciśnienie atmosferyczne.
- Airly Aura: Mierzy nie tylko pyły zawieszone, ale również zanieczyszczenia gazowe, takie jak NO₂ i NO.

Pomiar pyłów zawieszonych w tych czujnikach oparty jest na metodach optycznych. Urządzenia te są kompaktowe, odporne na warunki atmosferyczne i skalibrowane pod

kątem warunków lokalnych, co zapewnia ich niezawodne działanie w zróżnicowanych środowiskach.

Airly stosuje rygorystyczny, dwuetapowy proces kalibracji w celu zapewnienia najwyższej dokładności i niezawodności swoich czujników PM. W pierwszym etapie wszystkie czujniki są kalibrowane w kontrolowanych warunkach laboratoryjnych, gdzie są wystawiane na różne stężenia pyłów zawieszonych oraz zmienne warunki środowiskowe w specjalnej komorze testowej. Wyniki pomiarów są porównywane ze sprzętem referencyjnym w celu zapewnienia ich precyzji. Do instalacji w terenie dopuszczane są wyłącznie urządzenia spełniające surowe normy jakości. Po zainstalowaniu czujniki są dodatkowo dostrajane przy użyciu lokalnych współczynników kalibracyjnych, dostosowanych do warunków środowiskowych w danym regionie. Dzięki temu każde urządzenie zapewnia maksymalną dokładność pomiaru w swojej lokalizacji. Co więcej, sezonowe zmiany w źródłach zanieczyszczeń i ich charakterystyce wymagają okresowej rekalkibracji czujników. Airly dynamicznie aktualizuje współczynniki kalibracyjne, aby odzwierciedlać bieżące zmiany i zapewnić wysoką jakość danych w czasie (26 listopada 2025: <https://airly.org/>).

Lokalizacje czujników zostały starannie dobrane, z preferencją dla obszarów w pobliżu kanionów ulicznych. Miejsca stacji referencyjnych i czujników przedstawiono na rysunku 8. Lista stacji referencyjnych znajduje się w tabeli 2, natomiast lokalizacje czujników wyszczególniono w tabeli 3.



Rysunek 8: Lokalizacje stacji referencyjnych i sensorowych na terenie Warszawy (czarna linia przedstawia granicę miasta)

Tabela 2: Charakterystyka stacji referencyjnych

Nazwa strefy	Kod stacji	Lat	Lon	Typ obszaru	Typ stacji
Aglomeracja warszawska	MzWarAlNiepo	52.22	21.00	Miejski	Komunikacyjna
Aglomeracja warszawska	MzWarBajkowa	52.19	21.18	Miejski	Tło
Aglomeracja warszawska	MzWarChrosci	52.21	20.91	Miejski	Tło
Aglomeracja warszawska	MzWarTolstoj	52.29	20.93	Miejski	Tło
Aglomeracja warszawska	MzWarWokalna	52.16	21.03	Miejski	Tło
Mazowsze	MzOtwoBrzozo	52.12	21.24	Podmiejski	Tło
Mazowsze	MzPiasPulask	52.19	20.84	Podmiejski	Tło
Mazowsze	MzKonJezMos	52.08	21.11	Podmiejski	Tło

Tabela 3: Charakterystyka czujników

ID	Lokalizacja	Lat	Lon	Typ
6506	Aleja Wilanowska 79	52.17	21.05	Miejski
7627	Aleja Jerozolimskie 146	52.21	20.95	Kanion uliczny
761	Aleksandra Janowskiego 50	52.15	21.02	Miejski
5725	Algierska 6	52.22	21.08	Miejski
7853	Angorska 2	52.24	21.06	Miejski
4449	Antonio Corazziego 4	52.24	21.00	Miejski
7924	Aplikanka	52.22	21.00	Kanion uliczny
9318	Bogatki	52.13	21.02	Miejski
5918	Chmielna 73	52.23	21.00	Kanion uliczny
2679	Czestochowska	52.22	20.98	Miejski
3410	Filtrowa 75	52.22	20.99	Kanion uliczny
3177	Franciszka Klimczaka 2	52.16	21.08	Kanion uliczny
3229	Jana Szymczaka 5	52.23	20.96	Miejski
2717	Mokotow	52.18	21.04	Miejski
6979	Krucza 50	52.23	21.02	Miejski
6086	Marcina Kasprzaka 2	52.23	20.98	Kanion uliczny
2710	Newelska	52.25	20.94	Miejski
3165	Nowolipki 16	52.24	20.99	Kanion uliczny
7159	Odrodzenia	52.22	21.16	Miejski
4161	Ogrodowa 26A	52.24	20.99	Miejski
3731	Ostrodzka	52.33	21.05	Miejski
6612	Pachnaca	52.15	21.06	Miejski
3099	Podkowy	52.16	21.22	Miejski
7245	Solec	52.23	21.04	Miejski
4087	Stefana Korbońskiego	52.13	21.08	Miejski
4804	Terespolska 19	52.25	21.07	Miejski
8375	Torunska	52.30	21.02	Miejski
7256	Trocka 4	52.27	21.06	Miejski
2928	Wawozowa	52.13	21.07	Miejski
6127	Wawrzylca	52.19	20.99	Miejski
3569	Wiertnicza 88	52.17	21.08	Kanion uliczny
4937	Zeusa 45	52.25	20.91	Miejski
50237	Zwirki i Wigury 16	52.19	20.98	Miejski

3.5.1 Analiza czujników

Analiza danych dotyczących monitoringu jakości powietrza z 2022 roku ujawnia istotne różnice w pomiarach stężeń pyłu zawieszonego, wykonywanych przez tanie czujniki i stacje referencyjne. Oba systemy pomiarowe rejestrują podobne sezonowe trendy – wyraźne szczyty w marcu zarówno dla PM10, jak i PM2.5, przy czym wartości mierzone przez stacje referencyjne są w tym okresie znacznie wyższe. Dla PM10 stacje referencyjne notują w marcu stężenia sięgające $70 \mu\text{g}/\text{m}^3$, podczas gdy czujniki wskazują jedynie około 30-33 $\mu\text{g}/\text{m}^3$. Podobnie dla PM2.5 – stacje referencyjne rejestrują około 40 $\mu\text{g}/\text{m}^3$, a czujniki około 25 $\mu\text{g}/\text{m}^3$.


W miesiącach letnich (czerwiec – sierpień) obserwuje się (Rysunek 9) najniższe poziomy zanieczyszczeń w obu systemach, przy czym dla PM10 czujniki wskazują wartości rzędu 10-15 $\mu\text{g}/\text{m}^3$. Jesienią i wczesną zimą (październik – grudzień) oba systemy odnotowują wzrost stężeń, choć różnice pomiędzy nimi stają się ponownie zauważalne.

Analizując relację pomiędzy pomiarami czujników i stacji referencyjnych, widać, że stacje referencyjne przez cały rok konsekwentnie rejestrują wyższe stężenia PM10, a największe różnice występują w marcu oraz w okresie letnim (lipiec–sierpień). W przypadku PM2.5 zgodność pomiędzy systemami jest większa, zwłaszcza od czerwca do września, a w niektórych miesiącach jesiennych (październik – listopad) zdarza się, że pojedyncze czujniki wskazują wyższe wartości niż stacje referencyjne – zjawisko to nie występuje dla PM10.


Dane dotyczące odchylenia standardowego dodatkowo podkreślają te różnice (Tabeli 4 oraz 5). Stacje referencyjne wykazują wyższe odchylenia standardowe dla PM10 we wszystkich miesiącach, co wskazuje na większą zmienność ich pomiarów. Największe wartości odchylenia występują w marcu – 9.8 dla stacji referencyjnych wobec 4.1 dla czujników (PM10) oraz 6.1 wobec 3.3 (PM2.5). Czerwiec to jedyny miesiąc, w którym odchylenia standardowe dla PM2.5 są niemal identyczne (1.08 dla czujników i 1.05 dla stacji referencyjnych).

Niemniej jednak, w pozostałych miesiącach – gdy poziomy zanieczyszczeń są umiarkowane i mniej zmienne – niższe odchylenie standardowe czujników nie stanowi większego problemu w kontekście walidacji, ponieważ odczyty czujników są bliższe pomiarom referencyjnym. Oznacza to, że dane z czujników mogą być efektywnie wykorzystywane do walidacji modeli jakości powietrza w tych okresach, dostarczając wiarygodnych informacji o typowych warunkach. Jednak w miesiącach o najwyższych

stężeniach zanieczyszczeń, niezdolność czujników do uchwycenia pełnego zakresu i zmienności koncentracji ogranicza ich przydatność do walidacji modeli, zwłaszcza w ocenie epizodów wysokich stężeń.



Rysunek 9: Porównanie stężeń (a) PM2.5 i (b) PM10 na stacjach referencyjnych i lokalizacjach czujników



Rysunek 10: Monthly average of precipitation and temperature according to Institute of Meteorology and Water Management (IMGW) in 2022 in Warsaw

Tabela 4: Odchylenie standardowe dla sensorów i stacji referencyjnych dla PM10

Month	PM10 Czujniki	PM10 Stacje GIOŚ
Styczeń	2.09	3.60
Luty	1.39	3.91
Marzec	4.10	9.77
Kwiecień	1.92	4.45
Maj	1.43	5.16
Czerwiec	1.81	2.86
Lipiec	1.36	5.65
Sierpień	1.88	5.61
Wrzesień	2.07	4.32
Październik	3.49	6.46
Listopad	3.70	4.89
Grudzień	2.68	3.21

Tabela 5: Odchylenie standardowe dla sensorów i stacji referencyjnych dla PM2.5


Miesiąc	PM2.5 (Czujniki)	PM2.5 (Stacje GIOŚ)
Styczeń	1.41	2.31
Luty	0.96	1.54
Marzec	3.31	6.08
Kwiecień	1.34	2.53
Maj	1.06	1.43
Czerwiec	1.08	1.05
Lipiec	0.80	1.40
Sierpień	1.17	1.81
Wrzesień	1.45	1.63
Październik	2.89	2.13
Listopad	2.28	2.36
Grudzień	1.67	1.99

Analiza mapowania kwantyli na stacji Filtrowa (Rysunek 11) dostarcza szczególnie cennych informacji o relacji między pomiarami czujników i stacji referencyjnych. Zarówno

dla PM10, jak i PM2.5, zgodność pomiędzy systemami jest dobra przy niskich stężeniach. Dla PM10 wartości poniżej ok. $25 \mu\text{g}/\text{m}^3$ są zbliżone, jednak powyżej $40 \mu\text{g}/\text{m}^3$ wartości referencyjne rosną znacznie szybciej niż wskazania czujników, co oznacza, że czujniki istotnie zaniżają stężenia podczas epizodów smogowych. Przy najwyższych odczytach czujnika ($\sim 60 \mu\text{g}/\text{m}^3$ dla PM10) odpowiadająca wartość referencyjna przekracza $110 \mu\text{g}/\text{m}^3$, co pokazuje poważne niedoszacowanie przez czujniki w szczytowych momentach. Podobny wzorec występuje dla PM2.5 – zgodność przy niskich stężeniach jest dobra, ale powyżej ok. $30 \mu\text{g}/\text{m}^3$ wartości referencyjne rosną szybciej niż wskazania czujników. Gdy czujnik wskazuje ok. $40 \mu\text{g}/\text{m}^3$ dla PM2.5, wartość referencyjna zbliża się do $85 \mu\text{g}/\text{m}^3$, co ponownie potwierdza znaczące zaniżenia podczas epizodów wysokich stężeń.

Podsumowując, analiza sezonowa pokazuje, że zimą (grudzień – luty) stężenia są umiarkowane, a różnice pomiędzy systemami – stosunkowo niewielkie. Wiosną (zwłaszcza w marcu) zgodność jest najgorsza, a różnice i odchylenia największe. Latem zgodność jest najlepsza, zwłaszcza dla PM2.5 w czerwcu, mimo najniższych wartości bezwzględnych. Jesienią wraz ze wzrostem stężeń ponownie rosną rozbieżności.

Wnioski te wskazują, że tanie czujniki dobrze odwzorowują sezonowe trendy zanieczyszczeń podobnie jak stacje referencyjne, jednak systematycznie zaniżają wartości podczas epizodów wysokich stężeń. To ograniczenie jest szczególnie widoczne na mapowaniach kwantyli, gdzie rozbieżności rosną wraz ze wzrostem stężenia. Dlatego kalibracja czujników powinna być ukierunkowana zwłaszcza na poprawę dokładności w okresach epizodów smogowych, zwłaszcza w marcu i miesiącach zimowych, gdy różnice są największe.



Rysunek 11: codzienne mapowanie kwantylowe PM10 w lokalizacji czujnika Filtrowa dla (a) PM10 i (b) PM2.5

3.6 Miary błędów statystycznych

Miary statystyczne zastosowane do oceny obejmują znormalizowany średni błąd (NMB), średni bezwzględny błąd ogólny (MAGE), pierwiastek średniokwadratowy błędu (RMSE) oraz współczynnik korelacji Pearsona.

NMB ocenia dokładność prognoz modelu poprzez porównanie średniego błędu (odchylenia) względem wartości obserwowanych. Definiuje się go za pomocą następującego równania: 3:

$$NMB = \frac{\sum_{i=1}^n (X_i - Y_i)}{\sum_{i=1}^n Y_i} \quad (3)$$

MAGE (średni bezwzględny błąd ogólny) mierzy średnią wielkość błędów między wartościami modelowanymi a obserwowanymi, nie uwzględniając kierunku tych błędów (czyli czy model przeszacowuje, czy niedoszacowuje). Miara ta definiowana jest równaniem 4:

$$MAGE = \frac{1}{n} \sum_{i=1}^n |X_i - Y_i| \quad (4)$$

RMSE (pierwiastek średniokwadratowy błędu) to miara statystyczna opisująca rozrzut różnic pomiędzy wartościami modelowanymi a obserwowanymi. RMSE jest równoważny odchyleniu standardowemu próby tych różnic i pozwala ocenić, jak duże są błędy predykcji modelu w jednostkach mierzonej wielkości. RMSE definiuje się równaniem 5:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (X_i - Y_i)^2} \quad (5)$$


Współczynnik korelacji Pearsona (R) jest miarą liniowej zależności pomiędzy dwiema zmiennymi i definiowany jest równaniem 6. Informuje on o sile i kierunku związku pomiędzy wartościami modelowanymi a obserwowanymi. Jednak w wynikach przedstawiono kwadrat współczynnika korelacji Pearsona, R^2 , który wskazuje, jaka część zmienności danych obserwowanych może być wyjaśniona przez model.

$$r = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2 \sum_{i=1}^n (Y_i - \bar{Y})^2}} \quad (6)$$

gdzie X_i oznacza wartości modelowane, Y_i oznacza wartości obserwowane, $\bar{X}$ i $\bar{Y}$ to średnie odpowiednio z X i Y , a n to liczba obserwacji.

4 Wyniki

Modelowanie stężeń PM10 i PM2.5 w ramach konfiguracji ATMO-Street dla Warszawy wiązało się z pewnymi wyzwaniami [30]. Rysunek 12 przedstawia średnie roczne stężenia PM10 i PM2.5, uwzględniające wszystkie źródła emisji w scenariuszu bazowym modelu ATMO-Street. Najwyższe poziomy PM10 zaobserwowano w dzielnicach centralnych, zachodnich i północno-wschodnich, co wymagało ich weryfikacji na podstawie danych pomiarowych.



Rysunek 12: The annual average of (a)PM2.5 and (b)PM10 concentrations ($\mu\text{g}/\text{m}^3$) for the base scenario

4.1 Walidacja wyników modelu dla PM10 i PM2.5

Rysunek 13 porównuje modelowane i obserwowane roczne średnie stężenia pyłów zawieszonych – odpowiednio PM10 i PM2.5 – w scenariuszu bazowym.


Na wykresie 13b dotyczącym PM10 większość punktów, zarówno tych reprezentujących stacje referencyjne (kółka), jak i sensory (gwiazdki), znajduje się powyżej linii referencyjnej. Oznacza to, że model ma tendencję do przeszacowywania rocznych średnich stężeń PM10 w porównaniu do wartości obserwowanych. Najwięcej punktów skupia się w zakresie obserwowanych wartości 15–25 $\mu\text{g}/\text{m}^3$, podczas gdy odpowiadające im wartości modelowane są wyraźnie wyższe, najczęściej od 25 do 35 $\mu\text{g}/\text{m}^3$. Widać także jeden punkt odstający (stacja komunikacyjna MzWarAlNiepo), gdzie obserwowane stężenie wynosi około 36 $\mu\text{g}/\text{m}^3$, a modelowane jest niższe – w tym przypadku model zaniża wartość.

Ta stacja wyraźnie odbiega od głównego trendu, w którym model zwykle niedoszacowuje wartości w porównaniu do obserwacji. Zarówno stacje referencyjne, jak i sensory wykazują podobne zachowanie, bez wyraźnych różnic między tymi typami pomiarów.

Na wykresie 13a, dotyczącym PM2.5, również model przeszacowuje stężenia PM2.5. Jednak skala tego przeszacowania jest mniejsza niż w przypadku PM10. Obserwowane wartości PM2.5 mieszczą się głównie w przedziale $12\text{--}20\ \mu\text{g}/\text{m}^3$, a modelowane – w zakresie $15\text{--}22\ \mu\text{g}/\text{m}^3$. Punkty są bardziej skupione wokół linii referencyjnej, co sugeruje lepszą zgodność modelu z rzeczywistością dla PM2.5 niż dla PM10. Również tutaj nie widać istotnych różnic pomiędzy wynikami z sensorów i stacji referencyjnych.

Podsumowując, oba wykresy pokazują, że model w scenariuszu bazowym systematycznie przeszacowuje stężenia pyłów zawieszonych, przy czym efekt ten jest silniejszy dla PM10. Zgodność modelu z danymi obserwowanymi jest lepsza dla PM2.5, a tendencje te są spójne zarówno dla sensorów, jak i stacji referencyjnych. Pomimo obecności kilku punktów odstających, ogólny trend jest wyraźny: model przewiduje wyższe stężenia pyłów niż te obserwowane w rzeczywistości.

Analiza przedstawionych wykresów potwierdza hipotezę dotyczącą niedoszacowania emisji pyłu z unosu wtórnego (resuspensji) w okresach suchych, szczególnie widoczną dla stacji komunikacyjnej będącej punktem odstającym na wykresach.




Rysunek 13: Walidacja modelu dla (a) PM2.5 i (b) PM10 w scenariuszu bazowym

W przypadku lata (Rysunek 14c) większość punktów, zarówno dla stacji referencyjnych, jak i czujników, znajduje się powyżej linii referencyjnej, co oznacza, że model wciąż ma tendencję do przeszacowywania stężeń pyłu PM10 względem wartości obserwowanych. Jednak stopień tego przeszacowania jest mniejszy niż porze roku zimowym. Obserwowane wartości PM10 latem mieszczą się głównie w przedziale $12\text{--}20\ \mu\text{g}/\text{m}^3$, natomiast

modelowane wartości zazwyczaj nie przekraczają $22 \mu g/m^3$. Wyjątkiem jest jedna stacja komunikacyjna, gdzie obserwacja wynosi około $\mu g/m^3$, a modelowana wartość jest wyraźnie niższa, co wskazuje na niedoszacowanie modelu w tej stacji. Ta znacząca różnica potwierdza, że w okresach suchych, kiedy nasilony jest proces resuspensji pyłu drogowego, model nie doszacowuje tego zjawiska.

Fakt, że marzec 2022 był wyjątkowo suchy (Rysunek 10) i praktycznie bez opadów, dostarcza dodatkowego wyjaśnienia dla obserwowanej rozbieżności. W takich warunkach atmosferycznych pył drogowy łatwiej ulega wtórnemu unoszeniu pod wpływem ruchu pojazdów oraz wiatru, co prowadzi do zwiększonych stężeń PM10 na stacjach komunikacyjnych. Parametryzacja tego procesu w modelu najwyraźniej nie uwzględnia w wystarczającym stopniu wpływu długotrwałych okresów bezdeszczowych na intensyfikację resuspensji. Ogólnie jednak rozrzut punktów jest stosunkowo niewielki, a model lepiej odwzorowuje rzeczywiste stężenia pyłu latem niż zimą.

Z kolei w okresie zimowym (Rysunek 14a) model wyraźnie przeszacowuje stężenia pyłu PM10. Większość punktów znajduje się znacznie powyżej linii referencyjnej, a różnice pomiędzy wartościami modelowanymi a obserwowanymi są dużo większe niż latem. Obserwowane stężenia zimą wahają się od około 17 do $35 \mu g/m^3$, podczas gdy modelowane wartości często przekraczają $30 \mu g/m^3$, a niektóre punkty osiągają nawet $39 \mu g/m^3$. Ta tendencja jest widoczna zarówno dla stacji referencyjnych, jak i czujników.




Rysunek 14: Walidacji dla PM10 w (a) zimie i (b) wiosnie, (c) lecie i (d) jesieni dla scenariusza bazowego

W przypadku analizy PM2.5, jak pokazuje przedstawiony na rysunku wykres, występują wyraźne różnice w różnych porach roku w dokładności modelowania, podobnie jak w przypadku PM10, jednak z pewnymi istotnymi odrębnościami.

Model systematycznie przeszacowuje stężenia PM2.5 w okresie zimowym. Obserwowane stężenia wahają się głównie w przedziale $15\text{--}20\text{ }\mu\text{g}/\text{m}^3$, podczas gdy modelowane wartości osiągają $20\text{--}25\text{ }\mu\text{g}/\text{m}^3$. Stopień przeszacowania jest jednak mniejszy niż w przypadku PM10 w tym samym okresie. W okresie letnim model wykazuje najlepszą zgodność z obserwacjami dla PM2.5. Obserwowane i modelowane stężenia są najniższe, mieszcząc się głównie w zakresie $8\text{--}12\text{ }\mu\text{g}/\text{m}^3$. Z powrotem widoczna jest tendencja do przeszacowania jesienią, choć mniej wyraźna niż zimą. Wartości obserwowane mieszczą się głównie w przedziale $15\text{--}20\text{ }\mu\text{g}/\text{m}^3$, a modelowane $20\text{--}25\text{ }\mu\text{g}/\text{m}^3$. W porównaniu do PM10, modelowanie PM2.5 wykazuje:

Lepszą ogólną zgodność modelu z obserwacjami, mniejszy stopień przeszacowania,

mniej wplyw unosu wtórnego, bardziej spójne zachowanie między stacjami referencyjnymi a czujnikami.



Rysunek 15: Walidacji dla PM2.5 w (a) zimie i (b) wiosnie, (c) lecie i (d) jesieni dla scenariusza bazowego


Lepsza zgodność modelu dla PM2.5 w porównaniu do PM10 może wynikać z:

- Mniejszego udziału grubszych frakcji pyłu ($2.5-10\ \mu g$), które dominują w procesie resuspensji i są trudniejsze do dokładnego zamodelowania.
- Dłuższego czasu przebywania PM2.5 w atmosferze, co prowadzi do bardziej jednolitego rozkładu przestrzennego i mniejszej zmienności lokalnej.

4.2 Miesięczne profile czasowe


Miesięczne profile stężeń PM10 i PM2.5 (Rysunek 16) na stacji komunikacyjnej ujawniają istotną anomalię w marcu 2022 roku, kiedy to zmierzone stężenia PM10 osiągnęły

prawie $70 \mu\text{g}/\text{m}^3$, przekraczając wartości uzyskane w obu scenariuszach modelowych. Podobnie, stężenia $\text{PM}_{2.5}$ również wykazały wyraźny wzrost, choć w mniejszym stopniu. Ta zauważalna różnica między PM_{10} a $\text{PM}_{2.5}$ wskazuje na znaczny wzrost udziału cząstek gruboziarnistych, co jest silnie związane z resuspensją pyłu z nawierzchni dróg. Ekstremalnie suchy marzec (opady wynoszące jedynie 0.4 mm w dniu 7 marca; Rysunek 10) prawdopodobnie spotęgował ten efekt, przyczyniając się do podwyższonych stężeń PM_{10} . Wiele badań potwierdza, że pomijanie resuspensji pyłu drogowego może prowadzić do niedoszacowania stężeń PM_{10} w środowisku miejskim [30, 25, 29, 6, 1].



Rysunek 16: Miesięczne Profile czasowe dla stacji komunikacyjnej MzWarAlNiepo dla stężenia (a) $\text{PM}_{2.5}$ i (b) PM_{10} ($\mu\text{g}/\text{m}^3$)


Na stacji tła (MzWarChrosci, Rysunek 17) obserwowano podobne sezonowe trendy, choć o mniejszej intensywności niż na stacji komunikacyjnej. Szczyt z marca sugeruje wspólny wpływ suchych warunków, chociaż efekt resuspensji był mniej wyraźny. Wzrost $\text{PM}_{2.5}$ był mniej intensywny niż PM_{10} , co wskazuje na mniejszą podatność drobnych cząstek na resuspensję. Bliskość stacji do obszaru miejskiego sprawia, że jest ona pod wpływem zarówno czynników naturalnych (np. opadów), jak i emisji antropogenicznych z pobliskich działań miejskich. Dodatkowo, powstawanie aerozoli wtórnych jest silnie zależne od warunków meteorologicznych, zwłaszcza podczas okresów suszy, kiedy stagnacja powietrza i zwiększone nasłonecznienie mogą sprzyjać kumulacji zanieczyszczeń wtórnych. Choć stężenia PM na stacji tła są niższe niż na stacji komunikacyjnej, anomalia marcowa pokazuje, że nawet obszary tła położone blisko miast są podatne na wzrost stężeń pyłu zawieszonego w suchych okresach.



Rysunek 17: Miesięczne Profile czasowe dla stacji odniesienia tła - MzWarChrosci dla stężenia (a) PM2.5 and (b) PM10 ($\mu\text{g}/\text{m}^3$)

4.3 Analiza scenariuszy i statystyczne miary błędów

Poza przeszacowaniami obserwowanymi zimą, najwyższe stężenia PM10 i PM2.5 wystąpiły w znanych punktach zapalnych (Rysunek 12). Wyniki te skłoniły do dokładniejszego przyjrzenia się cechom lokalnym, takim jak gęstość zabudowy i rodzaje stosowanych paliw grzewczych. W scenariuszu zmodyfikowanym w modelu ATMO-Street uwzględniono zaktualizowane dane o emisjach z sektora komunalno-bytowego, co doprowadziło do redukcji emisji nawet o 20% w tych punktach zapalnych. Rysunek 18 przedstawia różnice w stężeniach PM10 i PM2.5 pomiędzy dwoma scenariuszami, z wyraźnymi spadkami w obszarach dotkniętych niepewnościami związanymi z danymi o ogrzewaniu indywidualnym.




Rysunek 18: Różnica średniorocznego stężenia (a) PM2.5 i (b) PM10 ($\mu\text{g}/\text{m}^3$) w Warszawie pomiędzy scenariuszem Base i Revised

4.3.1 PM2.5


Obliczono wskaźniki: znormalizowany błąd średni (NMB), średni bezwzględny błąd ogólny (MAGE), pierwiastek średniokwadratowy błędu (RMSE) oraz współczynnik korelacji Pearsona (R) (równania 3–6). W scenariuszu bazowym wiele lokalizacji sensorów wykazywało ujemne wartości R^2 , co wskazuje na słabe dopasowanie modelu. Natomiast w scenariuszu zmodyfikowanym wartości R^2 były dodatnie, co świadczy o wyraźnej poprawie.

Wartości NMB w scenariuszu bazowym były zazwyczaj wysokie (40–60%) dla większości sensorów, wskazując na znaczne przeszacowanie. W scenariuszu zmienionym wartości te spadły do 10–20%, co znacznie poprawiło dokładność. Poprawa ta znalazła również odzwierciedlenie w obniżonych wartościach MAGE i RMSE. Zaktualizowane dane emisyjne skutecznie rozwiązały problem przeszacowania w dzielnicach Praga-Południe i Ochota, gdzie błędna klasyfikacja paliw prowadziła do zawyżonych wartości. Na przykład redukcja emisji o 3.7% i 5.6% odpowiednio na Angorskiej i Filtrowej poprawiła prognozy PM2.5 o 57% (Rysunek 19).



Rysunek 19: Miesięczne profile czasowe czujników stężenia $\text{PM}_{2.5}$ ($\mu\text{g}/\text{m}^3$) w (a) Angorskiej i (b) Filtrowej, (c) korbońskiego i (d) Wiertnicznej porównujące scenariusze Base i Revised

Tabela 6 wskazuje, że zaktualizowany scenariusz (Revised) ogólnie przyniósł lepsze wyniki w porównaniu do scenariusza bazowego (Base) na stacjach referencyjnych. Na stacji komunikacyjnej (MzWarAlNiepo) wartość R^2 wzrosła z -0,28 do 0,79, co oznacza poprawę o 64%. Jednak na niektórych stacjach tła poprawa była mniej wyraźna (np. na stacji MzWarChrosci odnotowano jedynie 28% poprawy), co sugeruje utrzymujące się przeszacowania w danych wejściowych modelu tła.



Rysunek 20: Wartości NMB dla (a) PM2.5 i (b) PM10 na stacjach referencyjnych dla zmienionego scenariusza w różnych porach roku

Rysunek 20a przedstawia sezonowe wartości NMB dla PM2.5 na stacjach referencyjnych w scenariuszu zaktualizowanym. Ilustracja ukazuje zarówno mocne strony, jak i wciąż istniejące słabości modelu w kontekście zmienności sezonowej. Zimą wartości NMB są na ogół wyższe na większości stacji, podczas gdy wiosną i latem błędy są bardziej zrównoważone, choć występują lokalne rozbieżności.


Wpływ zaktualizowanych emisji różni się w zależności od stacji. W okresach zimy i jesieni wiele lokalizacji wykazuje wyraźną poprawę wartości NMB w porównaniu do scenariusza bazowego, co podkreśla znaczenie dokładnego uwzględnienia emisji z ogrzewania mieszkań. Latem zmiany są niewielkie na większości stacji, co jest zgodne z mniejszym udziałem ogrzewania w poziomach PM w tym porze roku.

Szczególnie istotne poprawy odnotowano na stacjach miejskich położonych w pobliżu kanionów ulicznych – w szczególności MzWarAlNiepo i MzWarChrosci. MzWarAlNiepo, zlokalizowana wewnątrz kanionu, wykazała szczególnie silną poprawę, co dodatkowo potwierdza korzyści płynące z zastosowania zaktualizowanego scenariusza w gęsto zabudowanych obszarach miejskich.

Zimowa mapa walidacji przestrzennej (Rysunek 21) pokazuje konsekwentne przeszacowanie na większości stacji, szczególnie w centralnej i południowo-zachodniej Warszawie, gdzie błędy wynoszą od 2 do 5 $\mu\text{g}/\text{m}^3$. Przeszacowania te korelują z obszarami zdominowanymi przez domy jednorodzinne wykorzystujące mieszane paliwa, i pokrywają się z hotspotami stężeń tła widocznymi na Rysunku 5a. Wiosną ukazuje podobny, lecz mniej intensywny wzorec. Latem model wykazuje najlepszą skuteczność dla PM2.5 – z minimalnym błędem i bez wyraźnego wzoru przestrzennego powiązanego z typem zabudowy. Jesienią, gdy ogrzewanie zostaje wznowione, przeszacowania powracają w układzie zbliżonym do zimowego.

Porównując stacje referencyjne i czujniki, te pierwsze wykazują bardziej spójne wzorce

Seasonal PM2.5 Spatial Validation - Revised Scenario



Rysunek 21: Sezonowa przestrzenna walidacja PM2.5

przestrzenne związane ze strukturą zabudowy. Dane z czujników są bardziej rozproszone, co odzwierciedla wpływ warunków mikrośrodowiskowych.

Tabela 6: Miary błędów statystycznych dla PM2.5 na stacjach referencyjnych

Station	Base				Revised			
	R^2	NMB	MAGE	RMSE	R^2	NMB	MAGE	RMSE
MzOtwoBrzozo	-0.07	0.07	7.49	10.34	0.84	0.05	2.79	3.39
MzPiasPulask	-1.15	0.56	11.34	12.15	-0.22	0.46	7.78	8.44
MzWarAlNiepo	-0.28	0.21	6.28	6.87	0.79	0.09	2.24	2.76
MzWarBajkowa	-0.48	0.31	6.73	7.47	0.57	0.19	3.39	4.15
MzWarChrosci	-2.47	0.64	9.54	10.29	-0.89	0.46	6.86	7.53
MzWarTolstoj	-0.42	0.31	7.13	7.72	0.64	0.16	2.81	3.73
MzWarWokalna	-0.85	0.44	7.25	7.88	0.35	0.32	4.33	4.74


Tabela 7: Miary błędów statystycznych dla PM2.5 na lokalizacjach czujników

Sensor	Base				Revised			
	R^2	NMB	MAGE	RMSE	R^2	NMB	MAGE	RMSE
Algierska	-1.49	0.44	6.48	7.03	-0.13	0.37	5.61	6.71
Angorska	-0.97	0.38	7.53	8.35	0.68	0.16	3.23	3.79
Aplikancka	-23.93	0.91	9.86	10.09	-0.89	0.20	6.01	7.96
Chmielna	-7.06	-0.38	11.37	12.14	-8.92	-0.44	13.19	13.47
Corazziego	-0.54	0.25	5.55	6.46	0.84	0.07	1.96	2.54
Filtrowa	-2.22	0.49	7.45	8.23	0.62	0.20	3.22	3.75
Janowskiego	-0.57	0.27	6.09	6.84	0.69	-0.03	3.32	4.34
Jerozolimskie146	-1.51	0.37	5.52	6.09	-1.18	0.03	8.26	9.76
Kasprzaka	-1.73	0.36	5.71	6.38	0.57	0.17	3.02	3.45
Klimczaka	-0.97	0.39	7.03	7.60	0.64	0.17	3.10	3.79
Korbołskiego	-2.39	0.63	8.50	9.22	0.62	0.19	3.03	3.72
Krucza	-0.59	0.23	5.26	6.04	0.82	0.07	2.27	2.58
Newelska	-1.79	0.44	6.02	6.56	-0.28	0.38	5.12	5.53
Nowolipki	-3.43	0.67	7.58	8.47	-0.03	0.39	5.26	5.63
Odrodzenia	-0.39	0.25	5.95	6.81	0.69	0.15	3.34	3.61
Ogrodowa	-1.75	0.47	6.63	7.34	0.58	0.21	3.19	3.85
Podkowy	-0.78	0.39	7.54	8.27	0.77	0.15	2.76	3.19
Solec	-1.16	0.38	6.93	7.54	0.65	0.16	3.10	3.57
Szymczaka	-3.33	0.61	7.32	8.27	-0.40	0.41	5.51	5.99
Terespolska	-1.07	0.46	7.78	8.02	-0.38	0.17	6.11	7.78
Trocka	-0.73	0.39	7.49	8.02	-0.03	0.38	6.06	6.69
Wawrzylca	-1.42	0.40	6.45	7.10	0.70	0.15	2.82	3.42
Wiertnicza	-1.66	0.47	8.11	8.74	0.49	0.19	3.93	4.41
Wilanowska	-0.91	0.35	6.80	7.50	0.49	0.19	3.78	4.06
Zeusa	-0.72	0.27	5.41	6.16	0.50	0.21	3.44	3.87

4.3.2 PM10

Oceny statystyczne stężenia PM10 w stacjach referencyjnych (Tabela 8) wskazują na słabą zgodność modelu z danymi obserwacyjnymi w scenariuszu bazowym, z negatywnymi lub niemal zerowymi wartościami R^2 oraz znacznymi przeszacowaniami

(np. NMB dla MzPiasPulask = 54.78%, MzWarChrosci = 46.99%). Stacja ruchu MzWarAlNiepo osiągnęła nieco lepsze wyniki ($R^2 = 0.086$, NMB = -14.24%), jednak ogólna dokładność modelu pozostała niewystarczająca. W przeciwieństwie do tego, w scenariuszu poprawionym zaobserwowano wyraźne poprawy w R^2 , a także zmniejszenie NMB, MAGE i RMSE w większości stacji referencyjnych.




Rysunek 22: (a) wartości NMB dla PM10 na stacjach referencyjnych dla zmienionego scenariusza oraz (b) różnica NMB między Revised a Base scenariuszem w różnych porach roku


Sezonowa analiza NMB dla PM10 (Rysunek 20b) wskazuje na wyższe błędy systematyczne zimą, przy czym w scenariuszu poprawionym zaobserwowano istotne poprawy w obszarach miejskich. Jednak utrzymujące się błędy w tzw. „hotspotach” sugerują, że dalsze udoskonalenia modelowania emisji lokalnych są nadal konieczne (Rysunek 23b). Pomimo że scenariusz poprawiony znacząco zwiększył skuteczność modelu, nadal występują trudności w odwzorowaniu zdarzeń ekstremalnych oraz dynamiki resuspensji, szczególnie w warunkach suchych. Dalsze usprawnienia w zakresie wrażliwości meteorologicznej oraz modelowania pyłu z nawierzchni dróg są kluczowe dla dokładniejszych ocen jakości powietrza w miastach. Mapy walidacyjne PM10 (Rysunek 24) pokazują bardziej uporczywe i rozległe przeszacowania niż w przypadku PM2.5. Mapy zimowe ujawniają silne dodatnie błędy ($5\text{--}10\text{ }\mu\text{g}/\text{m}^3$) w prawie wszystkich lokalizacjach sensorów. Wiosną przeszacowania utrzymują się, zwłaszcza w punktach pomiarowych, wykazując większe rozbieżności model–obserwacja niż dla PM2.5. Latem jakość odwzorowania nieco się poprawia – przeszacowania maleją, a niektóre czujniki wykazują wartości zbliżone do neutralnych lub nawet ujemne błędy, szczególnie w przypadku stacji ruchu. Stacje referencyjne natomiast wykazują lepszą zgodność z obserwacjami przez cały rok.

Tabela 8: Miary błędów statystycznych dla PM10 na stacjach referencyjnych

Station	Base				Revised			
	R^2	NMB	MAGE	RMSE	R^2	NMB	MAGE	RMSE
MzOtwoBrzozo	-0.08	0.07	10.08	13.64	0.66	0.06	5.57	6.26
MzPiasPulask	-1.4	0.55	16.03	16.53	-1.83	0.54	12.3	14.38
MzWarAlNiepo	-0.09	-0.14	7.25	14.98	0.2	-0.16	6.99	10.27
MzWarBajkowa	-0.15	0.15	8.84	10.10	0.25	0.11	6.14	7.10
MzWarChrosci	-1.18	0.47	14.23	14.40	-0.81	0.39	9.23	10.85
MzWarTolstoj	-0.86	0.41	11.93	12.10	-0.42	0.33	7.43	8.65
MzWarWokalna	-0.85	0.39	10.77	11.27	-0.07	0.33	6.79	7.59



(a)




(b)

Rysunek 23: Różnica NMB pomiędzy scenariuszem Revised i Base dla (a) PM2.5 i (b) PM10 w różnych porach roku

Rozbieżność między danymi z czujników a pomiarami referencyjnymi, zaobserwowana wcześniej, sugeruje, że wyników modelu nie można wiarygodnie analizować w lokalizacjach sensorów. Pomimo wprowadzonych usprawnień, oba scenariusze nie były w stanie uchwycić ekstremalnego szczytu stężeń PM10 w marcu na stacjach miejskich. Chociaż w modelu uwzględniono resuspensję pyłu drogowego, emisje te zostały niedoszacowane w warunkach skrajnie suchych, co ujawnia ograniczoną czułość modułu OSPM na zmienność meteorologiczną. Jest to znane ograniczenie OSPM [35, 5, 20]. W rzeczywistości cząstki zawieszone w kanionach ulicznych mają tendencję do pozostawania w obiegu lokalnym: opadają na powierzchnię, są ponownie wzbijane i ten cykl powtarza się wielokrotnie. Tego rodzaju wielokrotna resuspensja nie jest dokładnie odwzorowana w OSPM, ani w obecnych parametryzacjach resuspensji. Rysunek 22a sugeruje niewielkie poprawy w scenariuszu poprawionym, jednak nadal występują istotne niepewności.

Seasonal PM10 Spatial Validation - Revised Scenario




Rysunek 24: Sezonowa przestrzenna walidacja PM10

4.4 Wpływ czynników meteorologicznych

Dane temperaturowe dla stycznia, modelowane w ramach niniejszego badania, zostały porównane z danymi obserwacyjnymi z Instytutu Meteorologii i Gospodarki Wodnej. Analiza wykazała, że okresy wysokiego zanieczyszczenia pokrywały się z bardzo niskimi temperaturami, szczególnie w dniach 7–14 stycznia, kiedy temperatury modelowane były niższe niż obserwowane. Chłodniejsze warunki zwiększyły zapotrzebowanie na ogrzewanie, co potwierdza wskaźnik stopniodni grzewczych (HDD), będący kluczowym parametrem w obliczaniu emisji z sektora mieszkaniowego w modelu GEM-AQ. W rezultacie model przewidywał stężenia zanieczyszczeń w tym okresie oraz w całym styczniu.

Pomimo prób poprawy emisji z sektora mieszkaniowego, różnica w stężeniach zanieczyszczeń między scenariuszami Bazowym a Poprawionym była w tym okresie minimalna. Prawdopodobnie wynika to z faktu, że stacje takie jak MzWarChrosci znajdują się w dzielnicach z dużym udziałem zabudowy jednorodzinnej, gdzie model

emisji zakłada mieszanę różnych paliw grzewczych. W związku z tym poprawki wprowadzone w scenariuszu Poprawionym miały ograniczony wpływ. Podobny wzorec zaobserwowano na stacji MzPiasPulask, przy czym zarówno MzWarChrosci, jak i MzPiasPulask konsekwentnie wykazywały silnie dodatnie wartości NMB we wszystkich porach roku, szczególnie zimą i jesienią (zob. Rysunek 20b).



Rysunek 25: Porównanie temperatury i stężenia pyłu PM10 w miejscu występowania MzWarChrosci w styczniu 2022 r.

5 Podsumowanie

Raport przedstawia kompleksową analizę modelowania jakości powietrza w Warszawie, koncentrując się na stężeniach pyłów zawieszonych PM10 i PM2.5 z wykorzystaniem łańcucha modeli ATMO-Street. Badanie obejmuje szczegółową ocenę emisji z sektora komunalno-bytowego oraz transportowego, a także walidację modelu na podstawie danych z referencyjnych stacji pomiarowych i tanich sensorów.

- Do oceny jakości powietrza wykorzystano łańcuch modeli ATMO-Street, integrujący

modele GEM-AQ (tło), IFDM (dyspersja lokalna) oraz OSPM (efekt kanionów ulicznych).

- Emisje z sektora komunalno-bytowego oszacowano na podstawie krajowej inwentaryzacji oraz danych z Centralnej Ewidencji Emisyjności Budynków (CEEB), uwzględniając szczegółowe cechy budynków i rodzaje paliw.
- Emisje transportowe wyznaczono na podstawie danych GPS z aplikacji Yanosik i wskaźników COPERT, z korektą uwzględniającą strukturę ruchu z miejskiego modelu Warszawy.
- Uwzględniono również emisje wtórne pyłu drogowego (resuspensja) na podstawie modelu VEIN i wskaźników AP-42, z kalibracją współczynników „silt loading” w zależności od natężenia ruchu i warunków pogodowych.
- Dane meteorologiczne i tła stężeń pochodziły z modelu GEM-AQ, a przestrzenne dane o zabudowie z BDOT10k.
- Do walidacji wykorzystano dane z dziewięciu stacji referencyjnych GIOŚ oraz 31 sensorów Airly, zlokalizowanych głównie w pobliżu kanionów ulicznych.
- Analiza wykazała, że tanie czujniki dobrze odwzorowują sezonowe trendy zanieczyszczeń, jednak systematycznie zaniżają wartości podczas epizodów wysokich stężeń, szczególnie dla PM10.
- Największe różnice między czujnikami a stacjami referencyjnymi występowały w marcu i podczas epizodów smogowych, co wskazuje na konieczność lepszej kalibracji sensorów w tych okresach.
- W scenariuszu bazowym model ATMO-Street systematycznie przeszacowywał stężenia PM10 i PM2.5 względem obserwacji, szczególnie zimą i w punktach o wysokim natężeniu ruchu.
- Podsumowując, model generalnie lepiej odwzorowuje sezonowe trendy PM2.5 niż PM10, z najlepszą zgodnością osiąganą w okresie letnim i największymi rozbieżnościami zimą. Przeszacowanie jest jednak mniej wyraźne niż w przypadku PM10, co sugeruje, że procesy odpowiedzialne za tworzenie i dyspersję drobniejszych frakcji pyłu są lepiej reprezentowane w modelu ATMO-Street.
- Analiza wykazała, że pierwotna inwentaryzacja emisji zawierała błędy w klasyfikacji paliw grzewczych, prowadząc do przeszacowania udziału gazu i niedoszacowania spalania węgla i drewna.
- Wprowadzenie danych z CEEB oraz korekta emisji wtórnych (zwiększenie resuspensji pyłu o 17%) w scenariuszu zmodyfikowanym pozwoliły na redukcję emisji

PM10 i PM2.5 nawet o 20–22% w najbardziej zanieczyszczonych obszarach.

- Zaktualizowany scenariusz poprawił zgodność modelu z obserwacjami, obniżając wskaźniki błędów (NMB, MAGE, RMSE) i zwiększając współczynniki korelacji R^2 , zwłaszcza dla PM2.5.

Wnioski i rekomendacje

- Największe przeszacowania modelu występowały w okresach zimowych i wiosennych oraz w dzielnicach z przewagą indywidualnego ogrzewania paliwami stałymi.
- Model nadal ma ograniczoną zdolność odwzorowania ekstremalnych epizodów pyłowych, szczególnie w warunkach skrajnie suchych, co wynika z niedoskonałości parametryzacji resuspensji w module OSPM.
- Dalsze usprawnienia powinny koncentrować się na dokładniejszym modelowaniu emisji lokalnych, uwzględnieniu wielokrotnej resuspensji w kanionach ulicznych oraz lepszej kalibracji sensorów tanich w okresach wysokich stężeń.
- Wyniki podkreślają znaczenie aktualizacji danych emisyjnych oraz integracji różnych źródeł danych pomiarowych dla skutecznej oceny jakości powietrza w miastach.

Raport potwierdza, że precyzyjne modelowanie jakości powietrza wymaga ciągłej aktualizacji danych o emisjach, uwzględnienia specyfiki lokalnej zabudowy oraz warunków meteorologicznych, a także krytycznej oceny i kalibracji wykorzystywanych narzędzi pomiarowych.

6 Osiągnięcia w projekcie

Wyniki niniejszego projektu zostały zaprezentowane na trzech międzynarodowych konferencjach naukowych:

- 14th International Conference on Air Quality w Helsinkach, Finlandia
- HARMO22 w Parnawie, Estonia
- AGU Fall Meeting w Waszyngtonie, Stany Zjednoczone

Jeden artykuł konferencyjny, przedstawiony podczas HARMO22, został opublikowany i jest dostępny pod poniższym linkiem:

<https://sisu.ut.ee/wp-content/uploads/sites/641/H22-134-Anahita-Sattari.pdf>

Dwa artykuły naukowe zostały opublikowane w międzynarodowych czasopismach:

- Evaluating Traffic-Related Air Pollution in Urban Areas: A Case Study of Warsaw Using the ATMO-Street Model Chain – czasopismo Atmospheric Environment
- Enhancing ATMO-Street Model Accuracy through Emission Source Analysis using Large-Scale Sensor Data: A Warsaw Case Study – czasopismo Environmental Monitoring and Assessment

Literatura

- [1] Fulvio Amato, Martijn Schaap, Hugo AC Denier van der Gon, Marco Pandolfi, Andrés Alastuey, Menno Keuken, and Xavier Querol. Effect of rain events on the mobility of road dust load in two dutch and spanish roads. *Atmospheric Environment*, 62:352–358, 2012.
- [2] Maria Balduzzi. Biological effects of pm10 relevant to human health. *Annali Dell’istituto Superiore di Sanita*, 39(3):411–417, 2003.
- [3] Ruwim Berkowicz. Ospm-a parameterised street pollution model. *Environmental monitoring and assessment*, 65:323–331, 2000.
- [4] Rafael Borge, Julio Lumbreras, Javier Pérez, David de la Paz, Michel Vedrenne, Juan Manuel de Andrés, and M^a Encarnación Rodríguez. Emission inventories and modeling requirements for the development of air quality plans. application to madrid (spain). *Science of the Total Environment*, 466:809–819, 2014.
- [5] David De la Paz, Rafael Borge, Michel Vedrenne, Julio Lumbreras, Fulvio Amato, Angeliki Karanasiou, Elena Boldo, and Teresa Moreno. Implementation of road dust resuspension in air quality simulations of particulate matter in madrid (spain). *Frontiers in Environmental Science*, 3:72, 2015.
- [6] Julia C Fussell, Meredith Franklin, David C Green, Mats Gustafsson, Roy M Harrison, William Hicks, Frank J Kelly, Francesca Kishta, Mark R Miller, Ian S Mudway, et al. A review of road traffic-derived non-exhaust particles: emissions, physicochemical characteristics, health risks, and mitigation measures. *Environmental science & technology*, 56(11):6813–6835, 2022.
- [7] Lech Gawuc, Karol Szymankiewicz, Dorota Kawicka, Ewelina Mielczarek, Kamila Marek, Marek Soliwoda, and Jadwiga Maciejewska. Bottom-up inventory of residential combustion emissions in poland for national air quality modelling: current status and perspectives. *Atmosphere*, 12(11):1460, 2021.
- [8] Greta Gustafsson. Urban planning for better air quality: A case study of the low-traffic neighbourhoods in london, 2022.

- [9] Piotr Holnicki, Andrzej Kałuszko, Zbigniew Nahorski, Krystyna Stankiewicz, and Wojciech Trapp. Air quality modeling for warsaw agglomeration. *Archives of Environmental Protection*, 2017.
- [10] Christina Hood, Ian MacKenzie, Jenny Stocker, Kate Johnson, David Carruthers, Massimo Vieno, and Ruth Doherty. Air quality simulations for london using a coupled regional-to-local modelling system. *Atmospheric Chemistry and Physics*, 18(15):11221–11245, 2018.
- [11] H Hooyberghs, S De Craemer, W Lefebvre, S Vranckx, B Maiheu, E Trimpeneers, C Vanpoucke, S Janssen, FJR Meysman, and F Fierens. Validation and optimization of the atmo-street air quality model chain by means of a large-scale citizen-science dataset. *Atmospheric Environment*, 272:118946, 2022.
- [12] Sergio Ibarra-Espinosa, Rita Ynoue, Shane O’Sullivan, Edzer Pebesma, María de Fátima Andrade, and Mauricio Osses. Vein v0. 2.2: an r package for bottom-up vehicular emissions inventories. *Geoscientific Model Development*, 11(6):2209–2229, 2018.
- [13] J Jakubiak-Lasocka, J Lasocki, R Siekmeier, and Z Chłopek. Impact of traffic-related air pollution on health. *Environment exposure to pollutants*, pages 21–29, 2015.
- [14] Stijn Janssen, Gerwin Dumont, Frans Fierens, and Clemens Mensink. Spatial interpolation of air pollution measurements using corine land cover data. *Atmospheric Environment*, 42(20):4884–4903, 2008.
- [15] Ahmad Jonidi Jafari, Esmail Charkhloo, and Hasan Pasalari. Urban air pollution control policies and strategies: a systematic review. *Journal of Environmental Health Science and Engineering*, 19:1911–1940, 2021.
- [16] Iwona Kalinowska-Witowska, Patrycja Długosz, and Anna Gayer. Roczna ocena jakości powietrza w województwie mazowieckim, raport wojewódzki za rok 2023, 2024.
- [17] Iwona Kalinowska-Witowska, Monika Skolniak, and Barańska Krystyna. Roczna ocena jakości powietrza w województwie mazowieckim, raport wojewódzki za rok 2019, 2020.

- [18] JW Kaminski, L Neary, J Struzewska, JC McConnell, A Lupu, J Jarosz, K Toyota, SL Gong, J Côté, X Liu, et al. Gem-aq, an on-line global multiscale chemical weather modelling system: model description and evaluation of gas phase chemistry processes. *Atmospheric chemistry and physics*, 8(12):3255–3281, 2008.
- [19] Frank J Kelly and Julia C Fussell. Air pollution and public health: emerging hazards and improved understanding of risk. *Environmental geochemistry and health*, 37:631–649, 2015.
- [20] Matthias Ketzel, Steen Solvang Jensen, Ole Hertel, Thomas Ellermann, Helge Rørdam Olesen, and Ruwim Berkowicz. Tool for exploratory analysis of ospm model performance for long time series. 2011.
- [21] Haneen Khreis, Kees de Hoogh, Josias Zietsman, and Mark J Nieuwenhuijsen. The impact of different validation datasets on air quality modeling performance. *Transportation Research Record*, 2672(25):57–66, 2018.
- [22] W Lefebvre, F Fierens, E Trimpeneers, S Janssen, K Van de Vel, F Deutsch, P Viaene, J Vankerkom, G Dumont, C Vanpoucke, et al. Modeling the effects of a speed limit reduction on traffic-related elemental carbon (ec) concentrations and population exposure to ec. *Atmospheric Environment*, 45(1):197–207, 2011.
- [23] Wouter Lefebvre, Martine Van Poppel, Bino Maiheu, Stijn Janssen, and Evi Dons. Evaluation of the rio-ifdm-street canyon model chain. *Atmospheric Environment*, 77:325–337, 2013.
- [24] Lu Liang and Peng Gong. Urban and air pollution: a multi-city study of long-term effects of urban landscape patterns on air quality trends. *Scientific reports*, 10(1):18618, 2020.
- [25] Jakub Linda, Amra Hasečić, Jiří Pospíšil, Libor Kudela, and Jáchym Brzezina. Impact of wind-induced resuspension on urban air quality: a cfd study with air quality data comparison. *npj Climate and Atmospheric Science*, 8(1):74, 2025.
- [26] World Health Organization et al. Health effects of particulate matter: policy implications for countries in eastern europe, caucasus and central asia. In *Health effects of particulate matter: policy implications for countries in eastern Europe, Caucasus and central Asia*. 2013.

- [27] Daniel R Peters, Olalekan AM Popoola, Roderic L Jones, Nicholas A Martin, Jim Mills, Elizabeth R Fonseca, Amy Stidworthy, Ella Forsyth, David Carruthers, Megan Dupuy-Todd, et al. Evaluating uncertainty in sensor networks for urban air pollution insights. *Atmospheric Measurement Techniques Discussions*, 2021:1–23, 2021.
- [28] Khaiwal Ravindra, Sahil Kumar, Abhishek Kumar, and Suman Mor. Enhancing accuracy of air quality sensors with machine learning to augment large-scale monitoring networks. *npj Climate and Atmospheric Science*, 7(1):326, 2024.
- [29] Anahita Sattari and Hans Hooyberghs. Validation of the atmo-street air quality model using a large-scale measurement data set over warsaw, poland. In *22nd International Conference on Harmonisation within Atmospheric Dispersion Modelling for Regulatory Purposes*, Pärnu, Estonia, June 2024. 10-14 June 2024.
- [30] Anahita Sattari, Hans Hooyberghs, Stijn Janssen, Joanna Struzewska, Lech Gawuc, Lisa Blyth, and Stijn Vranckx. Evaluating traffic-related air pollution in urban areas: A case study of warsaw using the atmo-street model chain. *Atmospheric Environment*, 2025. Pre-print.
- [31] R Sharma, OP Kurmi, P Hariprasad, and SK Tyagi. Health implications due to exposure to fine and ultra-fine particulate matters: a short review. *International Journal of Ambient Energy*, 45(1):2314256, 2024.
- [32] Prakash Thangavel, Duckshin Park, and Young-Chul Lee. Recent insights into particulate matter (pm_{2.5})-mediated toxicity in humans: an overview. *International journal of environmental research and public health*, 19(12):7511, 2022.
- [33] Shang-Shyue Tsai and Chun-Yuh Yang. Health benefits of reducing ambient levels of fine particulate matter: a mortality impact assessment in taiwan. *Journal of Toxicology and Environmental Health, Part A*, 86(18):653–660, 2023.
- [34] Yu-Fei Xing, Yue-Hua Xu, Min-Hua Shi, and Yi-Xin Lian. The impact of pm_{2.5} on the human respiratory system. *Journal of thoracic disease*, 8(1):E69, 2016.
- [35] Jian Zhong. *Modelling air pollution within a street canyon*. PhD thesis, University of Birmingham, 2016.