

# Stima della concentrazione di PM10 in Italia con modelli statistici spazio-temporali: esempi applicativi

# Stima della concentrazione di PM10 in Italia con modelli statistici spazio-temporali: esempi applicativi

---

### **Informazioni legali**

L'Istituto Superiore per la Protezione e la Ricerca Ambientale (ISPRA), insieme alle 21 Agenzie Regionali (ARPA) e Provinciali (APPA) per la protezione dell'ambiente, a partire dal 14 gennaio 2017 fa parte del Sistema Nazionale a rete per la Protezione dell'Ambiente (SNPA), istituito con la Legge 28 giugno 2016, n.132.

Le persone che agiscono per conto dell'Istituto non sono responsabili per l'uso che può essere fatto delle informazioni contenute in questa pubblicazione.

ISPRA - Istituto Superiore per la Protezione e la Ricerca Ambientale  
Via Vitaliano Brancati, 48 – 00144 Roma  
[www.isprambiente.gov.it](http://www.isprambiente.gov.it)

ISPRA, RAPPORTI 375/2022  
ISBN 978-88-448-1134-1

Riproduzione autorizzata citando la fonte

### **Elaborazione grafica**

Grafica di copertina: Sonia Poponessi - **ISPRA** – Area Comunicazione Ufficio Grafica  
Foto di copertina: Archivio **ISPRA**

### **Coordinamento pubblicazione online:**

Daria Mazzella  
**ISPRA** – Area Comunicazione

Ottobre 2022

---

**Autori**

Guido Fioravanti

Giorgio Cattani

Gianluca Leone

**ISPRA** – Dipartimento per la valutazione, i controlli e la sostenibilità ambientale - Area per il monitoraggio della qualità dell'aria e per la climatologia operativa

---

## Sommario

<b>1</b>	<b>Introduzione</b>	<b>4</b>
<b>2</b>	<b>Dominio dello studio e variabili utilizzate</b>	<b>7</b>
2.1	Dominio spaziale	7
2.2	Siti di monitoraggio e dati di concentrazione	8
2.3	Regressori spazio-temporali	10
2.3.1	Varabili meteorologiche	10
2.3.2	Spessore ottico dell'aerosol	10
2.3.3	Elevazione.	10
2.3.4	Eventi di trasporto di sabbie desertiche.	10
2.3.5	Emissioni del traffico stradale.	11
2.3.6	Superficie impermeabile.	11
<b>3</b>	<b>Sviluppo del modello spazio-temporale</b>	<b>12</b>
3.1	Specificazione delle distribuzioni a priori	12
<b>4</b>	<b>Implementazione del modello</b>	<b>14</b>
4.1	Parametri del modello	14
4.2	Validazione	17
<b>5</b>	<b>Applicazioni</b>	<b>20</b>
5.1	Stima ad alta risoluzione spaziale della concentrazione di $PM_{10}$ in Italia	21
5.2	Stima delle aree di superamento	24
5.3	Esposizione della popolazione	29
5.4	Andamenti stagionali e trend nel periodo 2013 -2020	31
<b>6</b>	<b>Conclusioni</b>	<b>35</b>
<b>7</b>	<b>Bibliografia</b>	<b>36</b>

---

# 1 Introduzione

L'inquinamento atmosferico può essere definito come la presenza in aria di una o più sostanze in concentrazione tale da avere la potenzialità di produrre un effetto avverso.

Gli inquinanti ritenuti prioritari tenuto conto dei loro effetti e dell'entità delle loro emissioni sono gas inorganici (biossido di zolfo, SO<sub>2</sub>; ossidi di azoto, NO<sub>x</sub>; biossido di azoto, NO<sub>2</sub>; monossido di carbonio, CO; ozono, O<sub>3</sub>), composti organici volatili (quali ad esempio benzene e formaldeide) e materiale particolato aerodisperso.

Il materiale particolato aerodisperso viene definito come una sospensione di particelle solide o liquide relativamente stabili nell'aria circostante (aerosol). Questa sospensione può essere costituita da una varietà di particelle di diversa dimensione e composizione in funzione della loro origine.

Gli indicatori utilizzati per la stima dell'esposizione al materiale particolato in aria ambiente sono:

- la concentrazione di massa del particolato inalabile (polveri totali sospese);
- la concentrazione di massa del particolato selezionato in base al diametro aerodinamico mediante teste selettive con taglio a 10 µm (PM<sub>10</sub>) che comprende tutte le particelle con diametro aerodinamico inferiore o uguale a 10 µm;
- la concentrazione di massa del particolato selezionato in base al diametro aerodinamico mediante teste selettive con taglio a 2,5 µm (PM<sub>2,5</sub>) che comprende tutte le particelle con diametro aerodinamico inferiore o uguale a 2,5 µm;
- la concentrazione in numero delle particelle totale o distribuita per intervalli dimensionali.

I primi tre parametri sono stati oggetto di normative nazionali e internazionali nell'ambito della valutazione della qualità dell'aria e dell'individuazione di misure atte a migliorarla. Oggi in Europa è prevista la valutazione della qualità dell'aria con riferimento alle frazioni PM<sub>10</sub> e PM<sub>2,5</sub>.

Questi sono i due parametri di riferimento, scaturiti da decine di studi epidemiologici, per le stime di effetto sanitario dell'esposizione al materiale particolato aerodisperso.

Ai livelli degli inquinanti rilevati in atmosfera contribuiscono anche alcune fonti naturali, in particolare le particelle trasportate a lunga distanza di origine desertica, l'aerosol marino, gli incendi naturali delle grandi aree forestali, le emissioni dei vulcani e le emissioni biogeniche.

Vari studi epidemiologici sugli effetti sanitari dell'inquinamento atmosferico da particelle, hanno evidenziato associazioni tra le concentrazioni in massa del PM<sub>10</sub> e un incremento sia di mortalità che di ricoveri ospedalieri per malattie cardiache e respiratorie nella popolazione generale. I soggetti ritenuti maggiormente esposti a tali effetti sono in particolare, gli anziani, i bambini, le persone con malattie cardiopolmonari croniche e affette da influenza o asma; su di essi si concentrano incrementi di mortalità e seri effetti patologici a seguito di esposizioni acute a breve termine. Ulteriori evidenze sono emerse considerando gli effetti sanitari a lungo termine conseguenti all'esposizione a basse concentrazioni di PM<sub>10</sub>. Tali effetti riguardano la mortalità ed altre patologie croniche come la bronchite e la riduzione della funzione polmonare e sono stati riscontrati anche a concentrazioni molto basse (Martuzzi et al., 2006; Langanke et al., 2015; Piscitelli et al., 2019).

L'incremento di tumore polmonare è stato associato all'inquinamento atmosferico, ed in particolare alla frazione fine dell'aerosol: il PM outdoor è stato inserito dall'Agenzia Internazionale per la Ricerca sul Cancro (IARC) tra i cancerogeni di gruppo 1 (agenti sicuramente cancerogeni per l'uomo) (IARC, 2016).

Alcuni composti in forma particellare hanno una particolare rilevanza igienico-sanitaria (idrocarburi policiclici aromatici, tra cui il benzo(a)pirene, e diversi metalli e semimetalli come arsenico, nichel, cadmio, mercurio e piombo).

Il Position Paper sul materiale particolato, curato per conto della Commissione Europea dal CAFE Working group (EC, 2004) raccomandava l'uso del PM<sub>2,5</sub> come principale metrica per valutare l'esposizione della popolazione ed è stata la base scientifica su cui si è sviluppata la legislazione oggi vigente.

Nella revisione delle Linee Guida della Qualità dell'Aria per l'Europa (OMS, 2021), l'OMS ha prodotto delle stime numeriche di rischio per una serie di effetti sanitari associati ad un incremento di 10 µg/m<sup>3</sup> della concentrazione media annuale per il PM<sub>10</sub> ed il PM<sub>2,5</sub>.

---

Nelle sue valutazioni l'OMS non stabilisce un valore al di sotto del quale non vi sia rischio, ma individua come limite inferiore per la media annuale il valore di  $15 \mu\text{g}/\text{m}^3$  per il  $\text{PM}_{10}$  e di  $5 \mu\text{g}/\text{m}^3$  per il  $\text{PM}_{2,5}$ , che sono i livelli più bassi per i quali è stato osservato un incremento della mortalità totale, di quella per cause cardiopolmonari, e di quella per cancro del polmone, con una confidenza migliore del 95%.

Effetti nocivi sono noti anche per diversi altri inquinanti, tra cui l'ozono e il biossido di azoto alla cui esposizione le stime sanitarie più accreditate attribuiscono una porzione significativa di morti premature e riduzione dell'attesa di vita (OMS, 2016; EEA, 2019, OMS, 2021).

La valutazione dell'esposizione della popolazione e della relativa variabilità spaziale e temporale outdoor rappresenta un passaggio fondamentale per gli studi epidemiologici che mettono in relazione l'esposizione all'inquinamento atmosferico e gli effetti sulla salute (Chu et al., 2015).

Un altro aspetto importante è la valutazione della qualità dell'aria ai sensi della normativa vigente (D.Lgs 155/2010 e s.m.i.).

Come riportato nel D.Lgs. 155/2010 (Art. 1) "La zonizzazione dell'intero territorio nazionale è il presupposto su cui si organizza l'attività di valutazione della qualità dell'aria ambiente. A seguito della zonizzazione del territorio, ciascuna zona o agglomerato è classificata allo scopo di individuare le modalità di valutazione mediante misurazioni e mediante altre tecniche in conformità alle disposizioni del presente decreto".

L'uso di modelli e stime obiettive è espressamente previsto dalla normativa vigente (D.Lgs. 155/2010 art. 5).

In particolare, la normativa prevede l'individuazione dell'area di superamento ovvero dell'area, ricadente all'interno di una zona o di un agglomerato, nella quale è stato valutato il superamento di un valore limite o di un valore obiettivo; tale area è individuata sulla base della rappresentatività delle misurazioni in siti fissi o indicative o sulla base delle tecniche di modellizzazione.

Se, in una o più aree all'interno di zone o di agglomerati, i livelli degli inquinanti di cui all'articolo 1, comma 2, superano i livelli critici di cui all'allegato XI, le regioni e le province autonome adottano, anche sulla base degli indirizzi espressi dal Coordinamento di cui all'articolo 20, le misure necessarie ad agire sulle principali sorgenti di emissione aventi influenza su tali aree di superamento ed a raggiungere i livelli critici nei termini prescritti.

Per questi scopi è necessario disporre di uno strumento in grado di stimare la variabilità spaziale e temporale delle concentrazioni di  $\text{PM}_{10}$  ad alta risoluzione spaziale applicabile omogeneamente su domini molto estesi (come ad esempio quello dell'intera penisola italiana).

Nella maggior parte dei casi è sufficiente che le stime abbiano risoluzione temporale almeno giornaliera (Cohen et al., 2017).

L'uso di modelli statistici spazio-temporali su scala regionale e continentale è rapidamente cresciuto e si è diffuso nella comunità scientifica negli ultimi 10 anni, in relazione ad alcuni oggettivi vantaggi rispetto all'approccio deterministico basato su modelli numerici: facilità di implementazione, necessità di moderate risorse di calcolo, alta risoluzione spaziale delle predizioni, disponibilità crescente di algoritmi e software open-source per l'implementazione ottima performance dei modelli e credibilità delle stime (Hoek, 2017; Shahrahiyni and Sodoudi, 2016).

Nella letteratura statistica, il problema di costruire mappe di concentrazioni spazialmente continue su domini di grandi dimensioni è stato affrontato da diverse angolazioni. Un approccio popolare è quello dei modelli lineari ad effetti misti (LMM) che combinano la possibilità di includere complesse strutture di correlazione, tramite effetti casuali facili da specificare al minimo costo computazionale (Galecki e Burzykowski, 2013). I LMM possono infatti essere facilmente implementati in un quadro "frequentista", utilizzando, tra gli altri, il popolare pacchetto R nlme (Pinheiro et al., 2020). L'uso di LMM con effetti casuali regionali è riportato in studi recenti come Kloog et al. (2015) e Stafoggia et al. (2017).

Uno svantaggio di questa metodologia è che la dipendenza spaziale è espressa attraverso effetti casuali discreti che sono legati alla geografia di aree definite, risultanti in mappe predittive con artefatti spaziali come riportato ad es. da Sarafian et al. (2019) o Zhang et al. (2018). Inoltre, un LMM non incorpora, nel prodotto finale (cioè le mappe della distribuzione spaziale della concentrazione di  $\text{PM}_{10}$ ) l'intera incertezza associata alle incognite (dati, parametri, struttura del modello). Quando i risultati dei modelli sono utilizzati ai fini della gestione della qualità dell'aria è importante per i decisori che tali incertezze siano adeguatamente esplicitate (Liu et al., 2008).

---

L'uso di modelli gerarchici bayesiani (Clark e Gelfand, 2006) è un altro approccio comune negli studi sulla qualità dell'aria (Blangiardo et al., 2019; Huang et al., 2018; Shaddick et al., 2017; Forlani et al., 2020). Questo approccio permette di modellare fenomeni complessi come una gerarchia di più semplici sotto-modelli, consentendo di affrontare la complessità di processi spazio-temporali in modo diretto. Covariate come l'orografia o la temperatura possono essere utilizzate per spiegare la variabilità su larga scala del fenomeno in esame, mentre la dipendenza residua può essere modellata attraverso un processo spazio-temporale che di solito si presume sia un campo aleatorio gaussiano (Gaussian random field, GRF). Inoltre, l'approccio bayesiano permette di gestire adeguatamente il problema della valutazione dell'incertezza delle stime finali.

Lo svantaggio principale è stato fino ad anni recenti, la difficoltà di applicare i modelli GRF in presenza di un grande volume di dati di input; questo ha limitato il loro possibile utilizzo per applicazioni ambientali su larga scala (Porcu et al., 2012). Infatti la maggior parte degli studi pubblicati fino al 2020 ha utilizzato i modelli GRF su domini spaziali relativamente piccoli, come aree urbane (Police e Jona Lasinio, 2010; Sahu, 2011) o regioni (nel contesto italiano si veda ad esempio Cameletti et al., 2011; Cocchi et al., 2007; Grisotto et al., 2016). Nel caso di applicazioni su grandi domini gli studi sono stati limitati alla stima della variabilità spaziale (Beloconi et al., 2018). A questo proposito, vale la pena osservare che il principale strumento inferenziale per i modelli gerarchici bayesiani, vale a dire la Markov Chain Monte Carlo (MCMC) (Gilks et al., 1995), nonostante l'esistenza di strumenti di programmazione come WinBUGS (Spiegelhalter et al., 1995), JAGS (Plummer, 2016) e Stan (Team, 2015), possono essere difficili da implementare per la comunità scientifica dedicata allo sviluppo applicativo, richiedendo molto tempo di calcolo e la capacità di apportare modifiche delle specifiche dei parametri di simulazione, che possono richiedere professionalità e conoscenze proprie dei programmatori.

Per alleviare l'onere di calcolo e adattare l'implementazione di modelli gerarchici spazio-temporali complessi sono state proposte diverse strategie (Heaton et al. (2019) per una revisione aggiornata). Una di queste, l'approccio SPDE (Stochastic Partial Differential Equation), ha ricevuto molta attenzione negli ultimi anni (vedi Bakka et al., 2018 e relative citazioni bibliografiche). L'approccio SPDE fornisce un modo per rappresentare un GRF continuo attraverso un Gaussian Markov Random Field (GMRF; Lindgren et al., 2011). Computazionalmente i GMRF sono molto più efficienti in quanto si basano su matrici sparse (Rue and Held, 2005).

Inoltre, un GRF con una rappresentazione SPDE può essere adattato in un modello bayesiano a struttura gerarchica utilizzando l'approccio INLA (Integrated Nested Laplace Approximation, Rue et al., 2009). INLA è un metodo deterministico (e non basato su simulazioni a differenza di MCMC) basato sull'approssimazione delle distribuzioni marginali a posteriori (viene usata l'approssimazione numerica di Laplace e altre approssimazioni numeriche e schemi di integrazione numerici) e di solito è più veloce e più preciso degli algoritmi MCMC. Ultimo, ma non meno importante, INLA-SPDE può essere implementato in R, usando il pacchetto R-INLA. Tutorial ed esempi sono disponibili sul sito web dedicato [r-inla.org](http://r-inla.org) o in diversi manuali (es. Blangiardo e Cameletti, 2015; Gomez-Rubio, 2020). Questo rende la metodologia INLA-SPDE uno strumento veloce, affidabile e facile da usare.

In questo studio sono stati elaborati una serie di indicatori ambientali geo-referenziati con elevata risoluzione spaziale (1 km<sup>2</sup>) e temporale (giornaliera) estesi al dominio geografico nazionale.

Per ciascun anno dal 2013 al 2020 sono stati sviluppati modelli bayesiani a struttura gerarchica con approccio INLA-SPDE ad alta risoluzione spazio-temporale, per la stima del particolato, con l'uso di predittori spazio-temporali e dati di monitoraggio della qualità dell'aria.

L'obiettivo è quello di dimostrare i vari possibili campi applicativi del metodo e realizzare un archivio di simulazioni giornaliere con risoluzione spaziale di 1km x 1km su un periodo significativo di 8 anni. Il framework metodologico e di validazione è quello descritto in Fioravanti et al., 2021.




## 2 Dominio dello studio e variabili utilizzate

### 2.1 Dominio spaziale

Il dominio dello studio è l'intero territorio nazionale a una risoluzione spaziale di 1 km<sup>2</sup>. La figura 2.1 illustra la griglia usata per costruire l'approssimazione SPDE del campo di Matérn continuo (per maggiori dettagli vedi paragrafo 3.1). L'orografia del territorio italiano è varia e complessa, con i due sistemi montuosi delle Alpi e degli appennini, la pianura padana, le due isole maggiori e i suoi 7500 chilometri di costa. Le condizioni climatiche sono varie ed esercitano un'importante influenza sulla variabilità spaziale e stagionale dei livelli osservati (e.g. Perrino 2020). Inoltre la penisola è spesso affetta da eventi di intrusione al suolo di sabbia desertica. Diversi studi hanno evidenziato un contributo di tali eventi alla media annuale valutabile tra 1 e 9 µg/m<sup>3</sup> con valori decrescenti da sud a nord (Matassoni et al., 2009; Pey et al., 2013; Barnaba et al., 2017; Pikridas et al., 2018). Alcuni studi hanno anche evidenziato possibili effetti a breve termine associati agli eventi di intrusione di sabbie desertiche (Tobias et al., 2011; Samoli et al., 2013).

**Fig 2.1 – Dominio dello studio e mesh usata per costruire l'approssimazione SPDE del campo continuo di Matérn.**



Fonte: ISPRA

## 2.2 Siti di monitoraggio e dati di concentrazione

I dati di concentrazione dei vari inquinanti in atmosfera, misurati nel corso degli anni nelle stazioni di monitoraggio distribuite sul territorio nazionale, sono raccolti e archiviati in ISPRA nel database InfoARIA. I dati sono trasmessi dalle Regione e Province Autonome secondo quanto previsto dalla Decisione 2011/850/EU.

Ai fini di questo rapporto sono stati utilizzati i dati di PM10 disponibili attraverso questa fonte per il periodo dal 2013 al 2020. Per il PM10 in larga prevalenza (oltre l'80%) i dati di base sono medie giornaliere. Sono presenti comunque un certo numero di serie di dati con risoluzione temporale oraria e bioraria.

Ai fini delle successive analisi i dati sono stati aggregati su base giornaliera (medie giornaliere). Il criterio di aggregazione prescelto prevede la disponibilità di almeno 18 record orari al giorno (copertura giornaliera del 75%) per considerare valida una media giornaliera (ovvero 9 record nel caso di dati biorari). Nel caso di copertura insufficiente la relativa media giornaliera risulta come missing (e riportata come "NA").

Nella tabella 2.1 sono riportate le statistiche descrittive per ciascun anno.

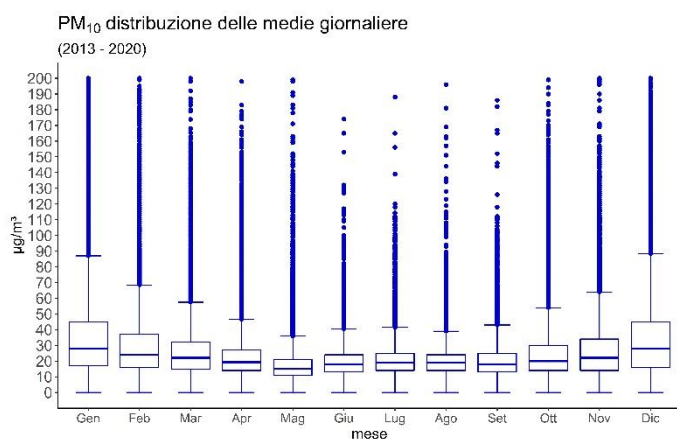
**Tab 2.1. Statistiche descrittive – media, deviazione standard (ds), e percentili delle distribuzioni – per le concentrazioni medie giornaliere di PM<sub>10</sub> (µg/m<sup>3</sup>). 2013 – 2020.**

anno	media	ds	perc5	perc25	mediana	perc75	perc95	N dati
2013	25.6	18.2	7.0	14.0	21.0	31.0	61.0	161576
2014	24.1	16.9	7.0	14.0	20.0	29.0	56.0	172778
2015	26.8	18.3	8.0	15.0	22.0	33.0	63.0	179546
2016	24.1	17.8	7.0	14.0	20.0	29.0	56.0	185407
2017	25.0	18.5	7.0	14.0	20.0	30.0	61.0	194096
2018	23.6	14.4	8.0	14.0	20.0	29.0	51.0	193734
2019	22.9	15.0	7.0	13.0	20.0	28.0	52.0	181707
2020	22.9	16.7	6.7	12.7	18.2	27.3	56.9	192412

Fonte: elaborazioni ISPRA su dati SNPA

Nella figura 2.2 è riportata la distribuzione mensile delle concentrazioni medie giornaliere estesa a tutto il periodo di osservazione. Come noto in generale i livelli sono mediamente più alti nei mesi invernali rispetto ai mesi estivi, tuttavia questo dipende in modo importante dalla zona geografica: la differenza appare molto marcata ad esempio nel bacino padano o nelle zone interne pianeggianti e vallive del centro sud, mentre i livelli appaiono più omogeneamente distribuiti nelle diverse stagioni nelle zone e costiere del centro-sud.

**Fig 2.2 - Distribuzione mensile delle concentrazioni medie giornaliere (µg/m<sup>3</sup>). 2013 – 2020.**

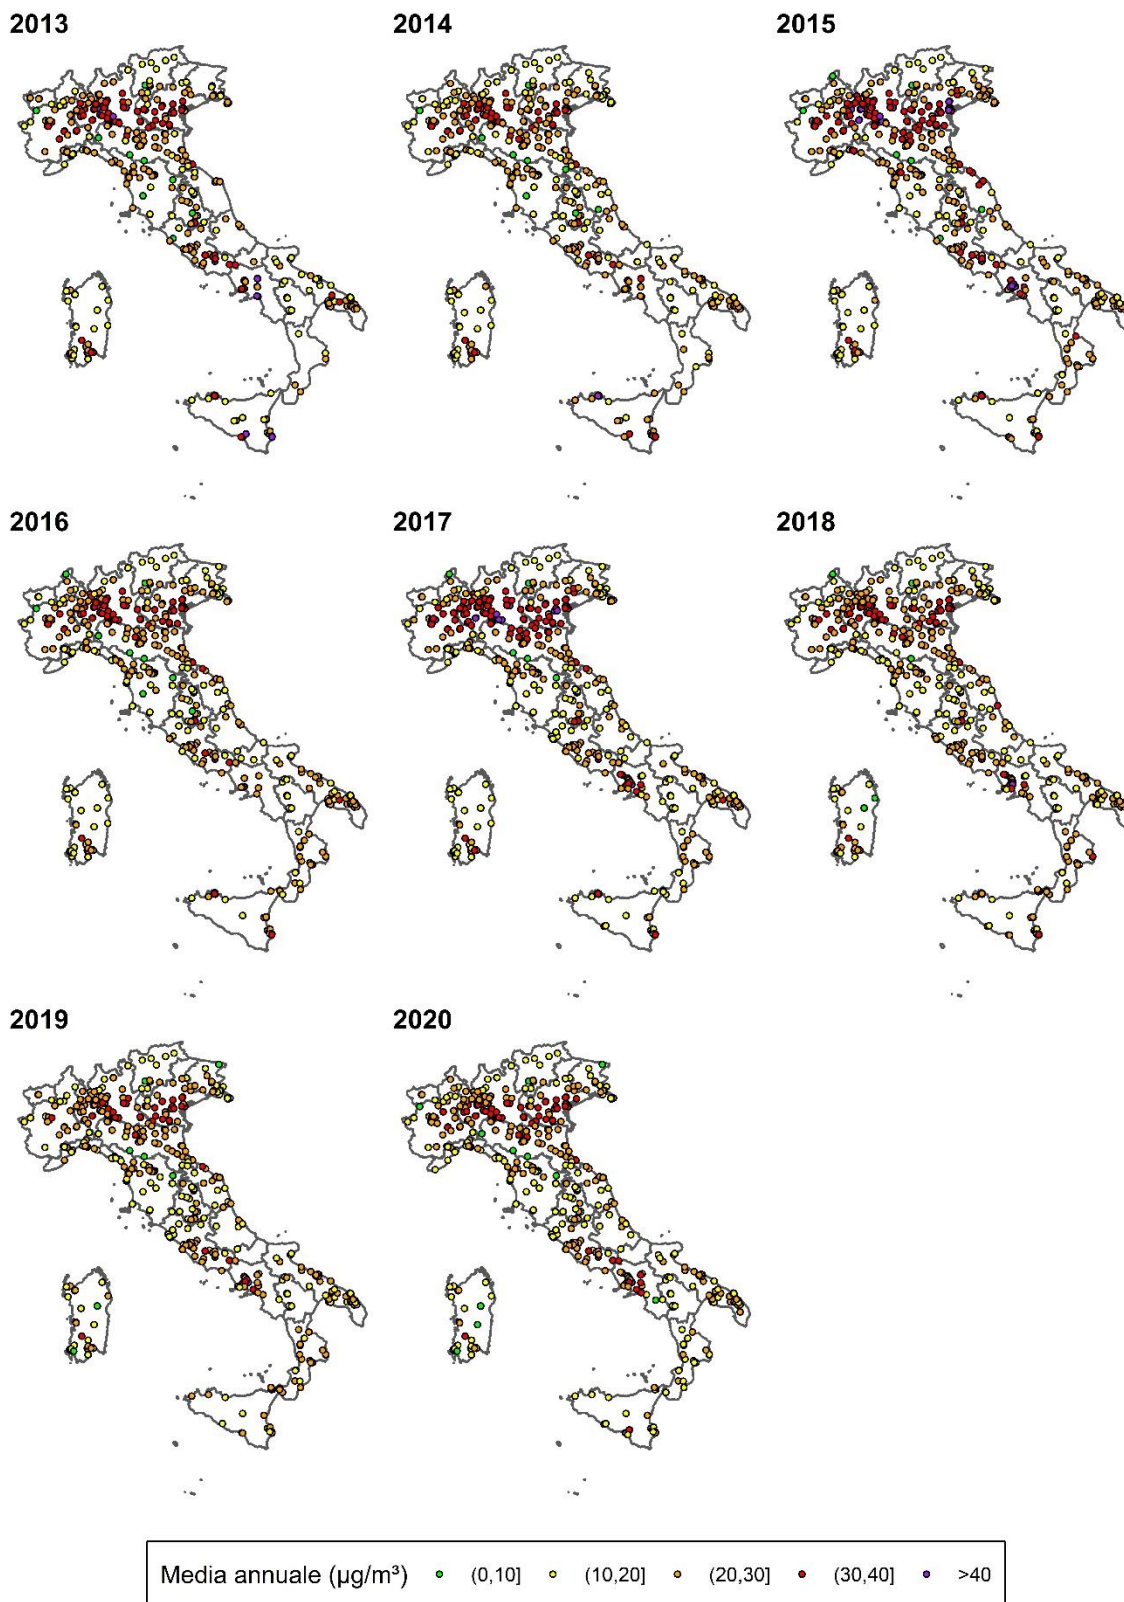


Fonte: Elaborazioni ISPRA su dati SNPA

Per una migliore leggibilità del grafico sono esclusi i valori superiori a  $200 \mu\text{g}/\text{m}^3$  registrati nel periodo 2013 – 2020 (202 valori pari al 0,014% dei casi) Fonte: elaborazioni ISPRA su dati SNPA

In figura 2.3 per ciascuno anno sono riportati i siti disponibili e la relativa media annuale.

**Figura 2.3 – Media annuale registrata nei punti di misura del  $\text{PM}_{10}$  utilizzati nel presente studio (2013-2020).**



Fonte: elaborazioni ISPRA su dati SNPA

---

## 2.3 Regressori spazio-temporali

Per ogni sito di monitoraggio, a partire da un ampio set di possibili predittori, abbiamo selezionato 11 variabili esplicative indipendenti (vedi tabella 2.2). I criteri per la selezione delle variabili è stata guidata da conoscenze a priori dei fenomeni in gioco come già sperimentato precedentemente (Fioravanti et al., 2021).

Ogni predittore numerico è stato standardizzato per avere media uguale a zero e deviazione standard uguale a 1.

### 2.3.1 Variabili meteorologiche

Poiché le concentrazioni degli inquinanti sono fortemente dipendenti dalle condizioni meteorologiche (e.g. Grange et al., 2018) le variabili che le descrivono hanno un ruolo importante nel modello sviluppato.

I dati meteorologici sono stati estratti dal set di dati ERA5 generato dal servizio Copernicus sui cambiamenti climatici. In particolare, per tutte le variabili selezionate, ad eccezione della stima dell'altezza del planetary boundary layer (hpbl) non contenuta in questo dataset, i dati sono stati estratti da ERA-land (terraferma) una versione regridded (spaziatura griglia 9 Km) della rianalisi climatica ERA5 (Hersbach et al. 2020) del Centro europeo per le previsioni meteorologiche a medio raggio (ECMWF); questi dati hanno risoluzione temporale oraria (UTC) e sono disponibili dal 1981 ad oggi. Il modo in cui la meteorologia influisce sulle concentrazioni di PM<sub>10</sub> viene valutato utilizzando 10 variabili (come precipitazioni totali, velocità del vento, umidità relativa, pressione superficiale) estratte dal set di dati ERA5-Land dal Copernicus Climate Data Store (<https://climate.copernico.eu/>). I dati orari sono stati estratti come file netcdf e mediati su base giornaliera.

Poiché i livelli di PM<sub>10</sub> possono essere influenzati dalle condizioni meteorologiche recenti è stata introdotta anche la variabile precipitazione cumulata del giorno precedente (Barnpadimos et al., 2012).

Un importante ruolo nei profili temporali degli inquinanti aerodispersi è determinato dai fattori che governano le proprietà dispersive dello strato limite planetario (planetary boundary layer, PBL) ovvero della parte di troposfera influenzata direttamente dalla presenza della superficie terrestre. A causa dell'apporto dell'energia solare si sviluppano forzanti radiative, e a causa dell'attrito tra aria e suolo si sviluppano forzanti meccaniche, che determinano lo sviluppo di moti turbolenti, dalla cui intensità e variabilità dipendono le proprietà dispersive del PBL, e le sue modificazioni su un tempo di scala orario o inferiore. Sono stati utilizzati i valori di altezza del PBL (hpbl) alle ore 00:00 e alle ore 12:00 ottenuti dai dati ERA5 single-levels (disponibili dal 1979 ad oggi, su tutto il globo terrestre, sempre con risoluzione oraria (UTC)). Sono in questo caso dati a risoluzione (latitudine x longitudine) pari a 0.25° x 0.25°.

### 2.3.2 Spessore ottico dell'aerosol

L' "Aerosol Optical Depth" (AOD) è un parametro che rappresenta lo spessore ottico colonnare di aerosol, ovvero l'integrale su tutta la colonna atmosferica del coefficiente di estinzione dell'aerosol (Hidy et al., 2009; Segura et al., 2017).

L'uso dell'AOD per rappresentare la variabilità nel tempo e nello spazio delle concentrazioni al suolo di particolato è documentato in diversi studi (Paciorek and Liu, 2012; Beloconi et al., 2018). Sono stati utilizzati i dati di AOD alla lunghezza d'onda di 550 nm del servizio global near-real-time (NRT) di CAMS (Copernicus Atmosphere Monitoring Service, <http://atmosphere.copernicus.eu>).

### 2.3.3 Elevazione.

I dati di elevazione del terreno sono stati ottenuti dal Global Multiresolution Terrain Elevation Data dell'USGS (Danielson and Gesch, 2011) messi a disposizione con una risoluzione di 30 secondi d'arco (circa 1 Km x 1 Km).

### 2.3.4 Eventi di trasporto di sabbie desertiche.

Nel nostro modello viene descritto il verificarsi di eventi di trasporto di sabbia desertica in termini di variabile dicotomica (presenza/assenza di evento). I giorni con eventi di trasporto di polvere desertica sono stati

identificati utilizzando le simulazioni messe a disposizione dal WMO Barcelona Dust Regional Center e dai partners del Sand and Dust Storm Warning Advisory and Assessment System (SDS-WAS) for Northern Africa, the Middle East and Europe (Perez et al., 2011).

### 2.3.5 Emissioni del traffico stradale.

Sono state considerate diverse variabili proxy per stimare l'impatto delle emissioni del traffico stradale, ma solo la distanza euclidea dalle strade principali è entrata nel modello finale. I dati della rete stradale provengono dal progetto OpenStreetMap (Haklay et al., 2010) e sono stati scaricati come file .pbf (vettoriali) dal servizio web Geofabrik ([www.geofabrik.de](http://www.geofabrik.de)).

### 2.3.6 Superficie impermeabile.

L'impermeabilità rappresenta la percentuale di soil sealing (la copertura del terreno con un materiale impermeabile). L'impermeabilità è un indicatore chiave di urbanizzazione (Attarchi, 2020). I dati relativi al grado di impermeabilità (0-100%) sono stati scaricati come file raster GeoTIFF dal servizio Copernicus Land Monitoring Service (Langanke, 2018).

**Tab 2.2 – Descrizione analitica delle variabili predittive usate**

<b>Variabile</b>	<b>Descrizione</b>	<b>Unità di misura</b>
<b>t2m</b>	<b>Temperatura media dell'aria a 2 metri d'altezza sulla superficie terrestre</b>	<b>°C</b>
<b>tp</b>	<b>Precipitazione cumulata sulla superficie terrestre</b>	<b>mm</b>
<b>ptp</b>	<b>Precipitazione cumulata sulla superficie terrestre del giorno precedente</b>	<b>mm</b>
<b>sp</b>	<b>Pressione dell'aria sulla superficie terrestre</b>	<b>hPa</b>
<b>pbl00</b>	<b>Altezza dello strato limite planetario alle ore 00:00</b>	<b>km</b>
<b>pbl12</b>	<b>Altezza dello strato limite planetario</b>	<b>km</b>
<b>dust</b>	<b>Presenza/assenza intrusione sabbia desertica</b>	<b>-</b>
<b>q_dem</b>	<b>Altitudine</b>	<b>m</b>
<b>d_a1</b>	<b>Distanza lineare dalla strada principale più vicina</b>	<b>m</b>
<b>AOD550</b>	<b>Spessore ottico dell'aerosol a 550 nm</b>	
<b>i_surface</b>	<b>Percentuale di suolo impermeabilizzato</b>	<b>-</b>

Fonte: ISPRA



### 3 Sviluppo del modello spazio-temporale

Sia  $y_m(t, s_i)$  la realizzazione del processo spazio-temporale  $Y_m(t, s_i)$  che rappresenta le concentrazioni log-trasformate della concentrazione del  $PM_{10}$  al giorno  $t = 1, \dots, T_m$  del mese  $m = 1, \dots, 12$  nella posizione  $s_i, i = 1, \dots, n$ . La trasformazione logaritmica è una scelta tipica per i dati con distribuzioni asimmetriche (*right-skewed*, Ott, 1990; Warsono et al., 2001) come i dati  $PM_{10}$ .

La nostra analisi esplorativa (risultati non riportati per brevità) ha evidenziato che l'impatto di ciascun predittore sulle concentrazioni di  $PM_{10}$  varia nel tempo. Di conseguenza, abbiamo sviluppato dodici modelli, uno per ogni mese dell'anno, tutti contenenti gli stessi termini. Un simile approccio è documentato, ad esempio, in Al-Hamdan et al. (2009) per la stima delle concentrazioni di  $PM_{2,5}$  nell'area metropolitana di Atlanta utilizzando i dati AOD.

Abbiamo ipotizzato il seguente modello:

$$y(t, s_i) = \mu + \mathbf{x}(t, s_i)\beta' + u(t, s_i) + z(s_i) + \varepsilon(t, s_i) \quad [1]$$

Poiché i modelli sono identici per ogni mese, nella formula sopra abbiamo ommesso l'indice  $m$  per semplificare la notazione. Nell'equazione [1],  $\mu$  è l'intercetta,  $\mathbf{x}(t, s_i) = (x_1(t, s_i), \dots, x_p(t, s_i))$  denota il vettore di predittori (vedi Tabella 2.2) nel sito  $s_i$  nel giorno  $t$  e  $\beta = (\beta_1, \dots, \beta_p)$  è il corrispondente vettore dei coefficienti. Il termine  $\varepsilon(t, s_i)$  rappresenta la misura dell'errore ed è definito da un processo di rumore bianco gaussiano indipendente da spazio e tempo con deviazione standard  $\sigma_\varepsilon$ . Il processo  $u(t, s_i)$  rappresenta la correlazione spazio-temporale residua una volta che la componente su larga scala  $\mathbf{x}(t, s_i)\beta'$  viene presa in considerazione. Poiché i livelli di particolato sono caratterizzati da correlazione inter-giornaliera, abbiamo assunto che  $u(t, s_i)$  cambi nel tempo secondo un processo autoregressivo del primo ordine con innovazioni spazialmente colorate:

$$u(t, s_i) = a u(t-1, s_i) + \omega(t, s_i) \quad [2]$$

Per  $t=2, \dots, T$  e  $|a| < 1$ .

Il termine  $v(s_i) \sim N(0, \sigma_v^2)$  rappresenta un effetto random Gaussiano temporalmente e spazialmente incorrelato che cattura parte della variabilità spaziale su piccola scala (nugget effect). Infine, il termine  $u(t, s_i)$  rappresenta la correlazione spazio-temporale residua per la quale è stata specificata una dinamica autoregressiva del primo ordine:

Le innovazioni  $\omega(t, s_i)$  hanno media pari a zero e distribuzione Gaussiana, non sono correlate temporalmente (ovvero  $COV(\omega(t, s_i), \omega(t, s_i')) = 0$  se  $t \neq t'$ ) mentre sono spazialmente correlate (ovvero  $COV(\omega(t, s_i), \omega(t, s_j)) = C(h)$  dove  $h$  è la distanza Euclidea tra il sito  $i$  e il sito  $j$  e  $C(h)$  è la funzione di covarianza di Matérn con varianza  $\sigma_\omega^2$  range  $\rho$  e parametro di smoothness  $\nu = 1$ .

Per maggiori dettagli teorici sulla struttura della covarianza qui applicata si veda per esempio Cameletti et al., 2011, Cameletti et al., 2013, Fioravanti et al., 2021.

#### 3.1 Specificazione delle distribuzioni a priori

Il modello descritto nel paragrafo precedente è stato sviluppato in un framework Bayesiano e risulta pienamente specificato una volta specificate le distribuzioni di probabilità a priori per il vettore  $\beta$  e per le deviazioni standard  $\sigma_\varepsilon, \sigma_z, \sigma_w$ , per i parametri di autocorrelazione e per il range della funzione di Matérn. Per gli elementi del vettore  $\beta$  sono state definite distribuzioni a priori non informative. Per i restanti parametri sono state usate distribuzioni a priori a complessità penalizzata (PC priors, Simpson et al., 2017). Queste sono state recentemente utilizzate per specificare distribuzioni a priori debolmente informative con il doppio intento di ridurre la complessità dei modelli statistici e nel contempo evitare l'overfitting. Per la deviazione standard dei parametri ( $\sigma_\varepsilon$  e  $\sigma_z$ ) le distribuzioni a priori sono generalmente definite come  $Prob(\sigma > u_\sigma) = \alpha_\sigma$  dove  $u_\sigma > 0$  è un quantile della distribuzione a priori e  $0 \leq \alpha_\sigma \leq 1$  è un valore di probabilità. Nella nostra analisi abbiamo fissato  $u_\sigma = 1$  per  $\sigma_\varepsilon$  e per  $\sigma_z$ . Questa scelta è stata motivata dal fatto che abbiamo verificato che la deviazione standard totale delle concentrazioni di  $PM_{10}$  log-trasformate varia tra 0,4 e 0,8 a seconda del mese, pertanto è molto probabile che la varianza di ogni componente sia effettivamente inferiore a 1.

---

Per quanto riguarda  $\rho$  e  $\sigma_\omega$  è stata utilizzata la distribuzione a priori suggerita da Fuglstad et al., 2019, specificata come segue:

$$Prob(\rho < u_\rho) = \alpha_\rho, Prob(\sigma_\omega > u_{\sigma_\omega}) = \alpha_{\sigma_\omega} \quad [3]$$

dove abbiamo fissato  $u_\rho = 150$ ,  $\alpha_\rho = 0.8$ ,  $u_{\sigma_\omega} = 1$ ,  $\alpha_{\sigma_\omega} = 0,01$ . Infine per il parametro di autocorrelazione  $a$  abbiamo usato la distribuzione a priori proposta da Sorbye & Rue (2017). Questa può essere specificata come  $Prob(a > u_a) = \alpha_a$  dove abbiamo fissato  $u_a = 0,8$  e  $\alpha_a = 0,3$ . Tale scelta deriva sia da precedenti applicazioni (e.g. Cameletti et al., 2013; Fioravanti et al., 2021) che da intrinseche restrizioni ai possibili valori che possono assumere  $u_a$  e  $\alpha_a$ .

---

## 4 Implementazione del modello

Per implementare il modello è stato usato il software R (R Core Team, 2018) e in particolare il pacchetto R-INLA (<https://www.r-inla.org>).

Per l'elaborazione delle mappe raster abbiamo usato il pacchetto R raster (<https://cran.r-project.org/web/packages/raster/index.html>), il software CDO il software CDO per l'elaborazione degli archivi netcdf (<https://code.mpimet.mpg.de/projects/cdo>), e il software PostGIS (Strobl, 2008).

### 4.1 Parametri del modello

La Fig. 4.1 illustra la distribuzione a posteriori per l'intercetta del modello ( $\mu$ ) e gli 11 coefficienti delle covariate  $\beta$  per ciascuno dei 12 modelli mensili elaborati per l'anno 2015.

Come previsto, molti dei parametri mostrano un chiaro comportamento stagionale.

La media a posteriori di  $\mu$  varia da un minimo di 2,42 a luglio a massimo di 3,4 a dicembre sulla scala logaritmica. Ciò corrisponde ad un livello medio di inquinamento che varia tra 11,2 e 40,0  $\mu\text{g}/\text{m}^3$ , dopo aggiustamento per covariate.

I predittori con l'effetto stagionale più pronunciato sono: la temperatura ( $t_{2m}$ ), l'altezza del pbl alle 00:00 ( $pbl_{00}$ ), l'altitudine ( $q_{dem}$ ) e la percentuale di superficie impermeabile ( $i_{surface}$ ). La temperatura tende ad avere un effetto positivo durante i mesi estivi e un effetto negativo o nullo durante l'inverno; l'altezza del pbl e l'altitudine hanno effetti negativi sulle concentrazioni di  $PM_{10}$ , con una magnitudo maggiore nella stagione invernale. Al contrario, la superficie impermeabile ha un effetto positivo, e anch'essa tende ad essere più grande durante l'inverno.

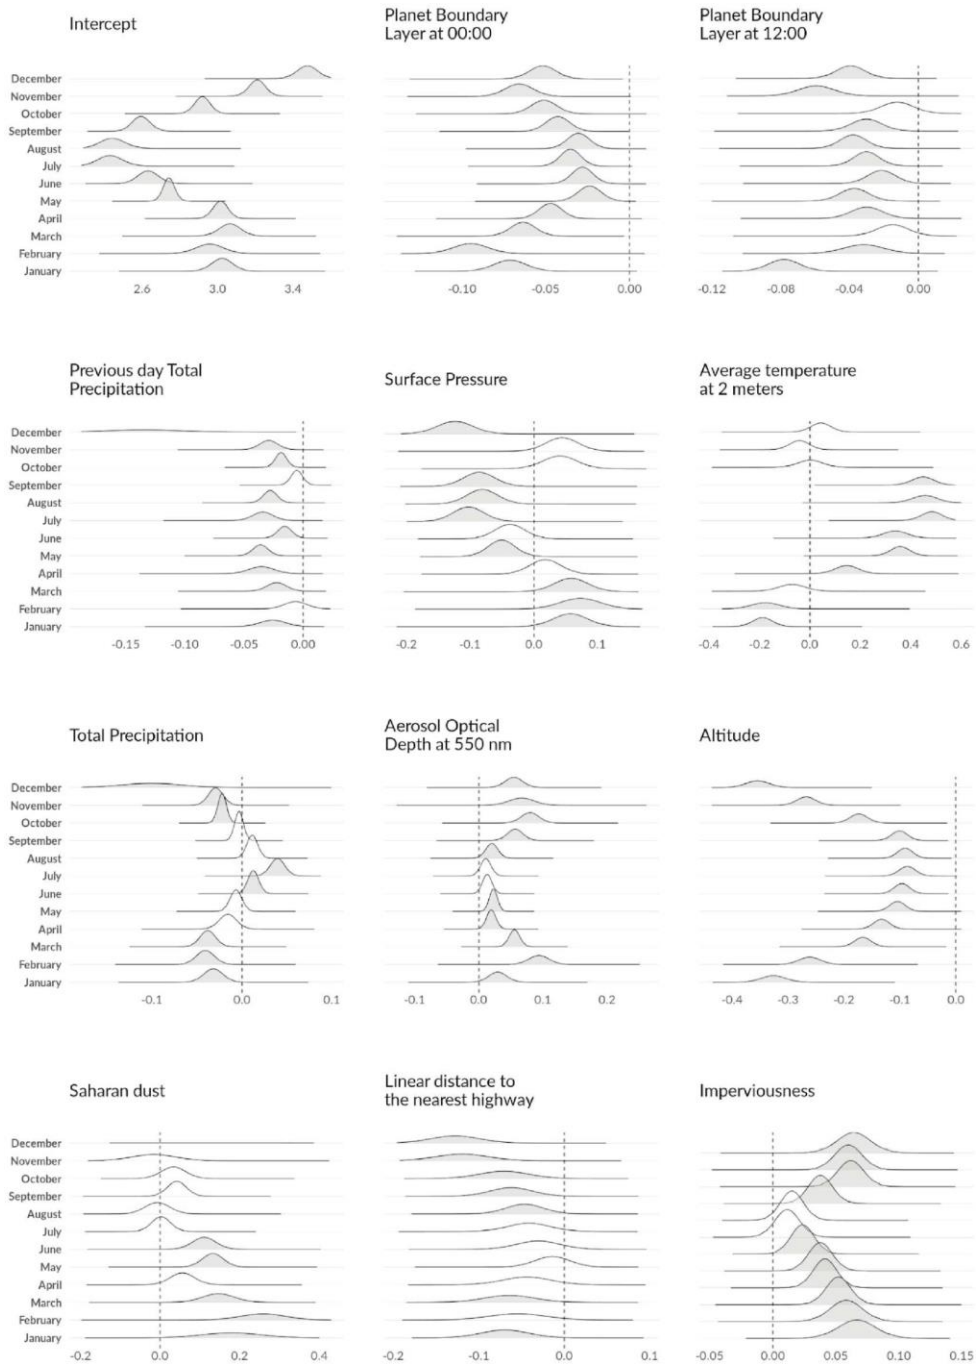
In generale, tutte le covariate, incluso l'AOD, hanno un effetto più forte nel periodo invernale, quando i livelli di  $PM_{10}$  sono più elevati e più variabili nello spazio e nel tempo. È interessante notare che un effetto stagionale dell'AOD è stato riportato anche in Al-Hamdan et al. (2009), ma di segno contrario (più debole durante la stagione fredda e relativamente forte durante la stagione calda).

Gli effetti di variazione stagionale mostrati in Fig. 4.1 supportano la nostra ipotesi iniziale che un'analisi di regressione mensile potrebbe migliorare l'accuratezza delle stime finali (Weber et al., 2010).

La deviazione standard a posteriori (sd) dei parametri  $\beta$  (che può essere dedotta dalla forma delle distribuzioni posteriori in Fig. 4.1) è piuttosto stabile di mese in mese. Le eccezioni sono la sd per la distribuzione dell'indicatore di presenza/assenza di eventi di trasporto di sabbie desertiche e la precipitazione totale (nel giorno imo e nel giorno precedente) nel mese di dicembre. Queste deviazioni standard sono molto maggiori rispetto a quelle degli altri mesi, a seguito del mancato verificarsi di eventi di trasporto e a causa di precipitazioni localizzate e particolarmente scarse per la stagione nel dicembre 2015.



**Fig 4.1 - Distribuzione a posteriori per l'intercetta del modello ( $\mu$ ) e gli 11 coefficienti delle covariate  $\beta$  per ciascuno dei 12 modelli mensili**



Le stime degli altri parametri del modello (medie a posteriori e deviazioni standard) sono riportate nella tabella 4.1.

Osserviamo che la componente spaziale mostra una variabilità maggiore sia rispetto all'errore di misura che rispetto all'effetto spaziale non strutturato. Tutte e tre le deviazioni standard presentano una variabilità stagionale, con valori più elevati in inverno che in estate. Anche il parametro dell'intervallo spaziale di correlazione  $\rho$  presenta una variazione nel corso dei mesi. La media a posteriori va da un minimo di circa 106 km in gennaio a un massimo di circa 239 km nel mese di agosto. L'intervallo spaziale del processo gaussiano  $u(t, s)$  è maggiore in estate, e mette in luce la presenza di un campo di particolato spazialmente più uniforme; la stessa osservazione vale per la deviazione standard a posteriori. Questo risultato riflette il fatto che, nel periodo estivo, le concentrazioni di  $PM_{10}$  sono caratterizzate da una bassa variabilità spaziale.

Infine, la media posteriore del coefficiente di autocorrelazione AR(1) a oscilla da 0,62 a 0,82 ma non c'è un chiaro andamento stagionale. Il valore piuttosto elevato del coefficiente di autocorrelazione conferma la buona probabilità che i valori rilevati nel giorno imo siano simili a quelli rilevati nel giorno precedente.

Per valutare se il modello riesce a cogliere la variabilità spazio-temporale delle osservazioni, mostriamo in Figura 4.2 i variogrammi spazio-temporali (Cressie e Wikle, 2011) per le concentrazioni di PM<sub>10</sub> (linee continue) e per i residui del modello (linee tratteggiate).

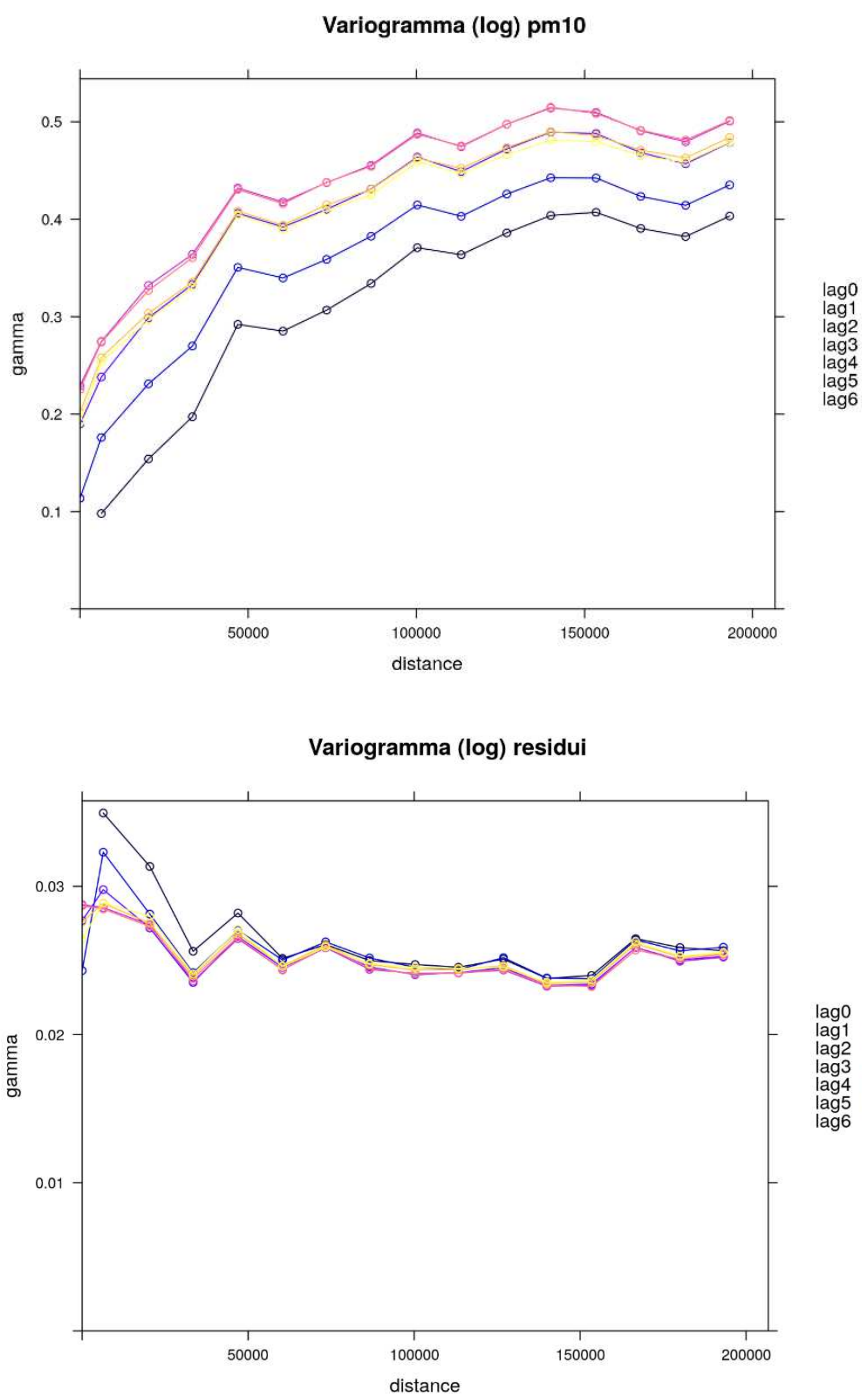
Si può osservare come la semivarianza aumenti con la distanza (asse x), suggerendo una dipendenza spaziale tra le osservazioni. Un comportamento simile è evidente quando osserviamo la semi-varianza lungo l'asse y per una data distanza: osserviamo che la semi-varianza aumenta con il lag temporale, suggerendo una dipendenza temporale dei dati. Quando osserviamo i variogrammi dei residui del modello la struttura di correlazione risulta quasi del tutto assente; dunque il modello sviluppato è in grado di catturare il segnale spazio-temporale e restituire dei residui non correlati.

**Tab 4.1 – Stime dei parametri del modello (medie a posteriori e deviazioni standard): coefficiente di autocorrelazione AR(1) ( $\alpha$ ), range spaziale del processo Gaussiano ( $\rho$ ), la deviazione standard dell'errore di misura ( $\sigma_\varepsilon$ ) deviazione standard della funzione di covarianza di Matern ( $\sigma_\omega$ ) per i dodici mesi dell'anno di esempio 2015.**

	$\alpha$	$\rho$	$\sigma_\varepsilon$	$\sigma_\varepsilon$	$\sigma_\omega$
<b>Gennaio</b>	<b>0.629 (-0.018)</b>	<b>106.23 (-4.186)</b>	<b>0.247 (-0.012)</b>	<b>0.197 (-0.002)</b>	<b>0.434 (-0.011)</b>
<b>Febbraio</b>	<b>0.656 (-0.017)</b>	<b>135.213 (-5.341)</b>	<b>0.207 (-0.01)</b>	<b>0.201 (-0.002)</b>	<b>0.513 (-0.014)</b>
<b>Marzo</b>	<b>0.656 (-0.018)</b>	<b>192.579 (-8.498)</b>	<b>0.162 (-0.008)</b>	<b>0.18 (-0.002)</b>	<b>0.432 (-0.014)</b>
<b>Aprile</b>	<b>0.742 (-0.019)</b>	<b>153.914 (-8.29)</b>	<b>0.151 (-0.007)</b>	<b>0.178 (-0.002)</b>	<b>0.361 (-0.014)</b>
<b>Maggio</b>	<b>0.624 (-0.02)</b>	<b>167.292 (-9.017)</b>	<b>0.163 (-0.007)</b>	<b>0.177 (-0.002)</b>	<b>0.289 (-0.008)</b>
<b>Giugno</b>	<b>0.743 (-0.023)</b>	<b>237.997 (-15.118)</b>	<b>0.157 (-0.006)</b>	<b>0.167 (-0.001)</b>	<b>0.282 (-0.013)</b>
<b>Luglio</b>	<b>0.823 (-0.018)</b>	<b>177.433 (-10.544)</b>	<b>0.163 (-0.007)</b>	<b>0.155 (-0.001)</b>	<b>0.263 (-0.014)</b>
<b>Agosto</b>	<b>0.704 (-0.022)</b>	<b>238.714 (-15.483)</b>	<b>0.159 (-0.006)</b>	<b>0.177 (-0.001)</b>	<b>0.256 (-0.011)</b>
<b>Settembre</b>	<b>0.697 (-0.019)</b>	<b>181.108 (-9.8)</b>	<b>0.161 (-0.007)</b>	<b>0.177 (-0.002)</b>	<b>0.319 (-0.011)</b>
<b>Ottobre</b>	<b>0.727 (-0.017)</b>	<b>164.188 (-7.097)</b>	<b>0.171 (-0.007)</b>	<b>0.176 (-0.002)</b>	<b>0.382 (-0.013)</b>
<b>Novembre</b>	<b>0.78 (-0.014)</b>	<b>105.514 (-3.908)</b>	<b>0.167 (-0.009)</b>	<b>0.153 (-0.002)</b>	<b>0.443 (-0.014)</b>
<b>Dicembre</b>	<b>0.825 (-0.014)</b>	<b>83.96 (-2.968)</b>	<b>0.209 (-0.012)</b>	<b>0.148 (-0.002)</b>	<b>0.41 (-0.015)</b>

Fonte: ISPRA

Fig 4.2 – Esempio di variogrammi mensili spazio-temporali per le concentrazioni osservate e per i corrispondenti residui del modello.



## 4.2 Validazione

Per valutare le prestazioni predittive del modello è stato effettuato uno studio di cross validation simile a quello presentato in Pirani et al. (2014).

Nello specifico, abbiamo stratificato i siti di monitoraggio in tre gruppi in base al tipo di area (urbana, suburbana e rurale). Un set di dati di convalida è stato identificato campionando il 10% dei siti di monitoraggio in ciascun gruppo, con il resto delle stazioni etichettate come set di dati di addestramento. Abbiamo usato il set di dati di addestramento per adattarsi al modello e prevedere le concentrazioni di  $PM_{10}$  sul set di dati di convalida. Infine, abbiamo confrontato i valori previsti con i valori osservati e sintetizzato i risultati utilizzando una serie di indicatori di performance. Il processo di campionamento è stato ripetuto tre volte, risultando in tre dataset di validazione e training.

Come misure di performance abbiamo scelto i seguenti indici:

- 1) la copertura empirica di intervalli credibili al 95% (IC 95%);
- 2) il coefficiente di correlazione;
- 3) la radice quadrata dell'errore quadratico medio (RMSE);
- 4) il bias.

Gli ultimi tre indici sono calcolati confrontando le concentrazioni osservate e la media prevista a posteriori di ciascun sito di monitoraggio. Per ogni set di dati di addestramento/validazione, sono stati calcolati i valori medi degli indicatori su tutte le stazioni. I risultati relativi a un anno di esempio (2015) sono riportati in Tabella 4.2 ed espressi in  $\mu\text{g}/\text{m}^3$ .

**Tab 4.2 – Statistiche dello studio di cross-validazione per l'anno di esempio 2015.**

	RMSE ( $\mu\text{g}/\text{m}^3$ )		Correlazione		Bias ( $\mu\text{g}/\text{m}^3$ )		Copertura (%)	
	Training	Validazione	Training	Validazione	Training	Validazione	Training	Validazione
<b>Gennaio</b>	<b>5.33</b>	<b>1.14</b>	<b>0.98</b>	<b>0.87</b>	<b>- 0.04</b>	<b>1.07</b>	<b>98.23</b>	<b>94.93</b>
<b>Febbraio</b>	<b>4.87</b>	<b>9.59</b>	<b>0.98</b>	<b>0.91</b>	<b>- 0.1</b>	<b>0.62</b>	<b>98.1</b>	<b>94.41</b>
<b>Marzo</b>	<b>4.24</b>	<b>7.43</b>	<b>0.97</b>	<b>0.89</b>	<b>- 0.07</b>	<b>0.54</b>	<b>97.66</b>	<b>94.64</b>
<b>Aprile</b>	<b>3.08</b>	<b>5.6</b>	<b>0.95</b>	<b>0.83</b>	<b>- 0.03</b>	<b>0.49</b>	<b>97.61</b>	<b>93.74</b>
<b>Maggio</b>	<b>3.06</b>	<b>5.31</b>	<b>0.95</b>	<b>0.83</b>	<b>- 0.03</b>	<b>0.28</b>	<b>97.86</b>	<b>95.16</b>
<b>Giugno</b>	<b>3.02</b>	<b>4.84</b>	<b>0.93</b>	<b>0.79</b>	<b>- 0.02</b>	<b>0.25</b>	<b>97.31</b>	<b>94.43</b>
<b>Luglio</b>	<b>3.47</b>	<b>6.38</b>	<b>0.92</b>	<b>0.71</b>	<b>- 0.01</b>	<b>0.29</b>	<b>97.41</b>	<b>94.56</b>
<b>Agosto</b>	<b>3.68</b>	<b>5.41</b>	<b>0.92</b>	<b>0.82</b>	<b>- 0.03</b>	<b>0.22</b>	<b>97.05</b>	<b>95.62</b>
<b>Settembre</b>	<b>3.68</b>	<b>5.63</b>	<b>0.94</b>	<b>0.85</b>	<b>0.01</b>	<b>0.55</b>	<b>97.51</b>	<b>95.24</b>
<b>Ottobre</b>	<b>3.21</b>	<b>6.05</b>	<b>0.97</b>	<b>0.89</b>	<b>- 0.01</b>	<b>0.61</b>	<b>97.8</b>	<b>94.61</b>
<b>Novembre</b>	<b>3.77</b>	<b>8.92</b>	<b>0.98</b>	<b>0.88</b>	<b>- 0.01</b>	<b>0.73</b>	<b>98.44</b>	<b>93.57</b>
<b>Dicembre</b>	<b>5.79</b>	<b>13.9</b>	<b>0.98</b>	<b>0.83</b>	<b>0.04</b>	<b>0.79</b>	<b>98.53</b>	<b>95.48</b>

Fonte: ISPRA

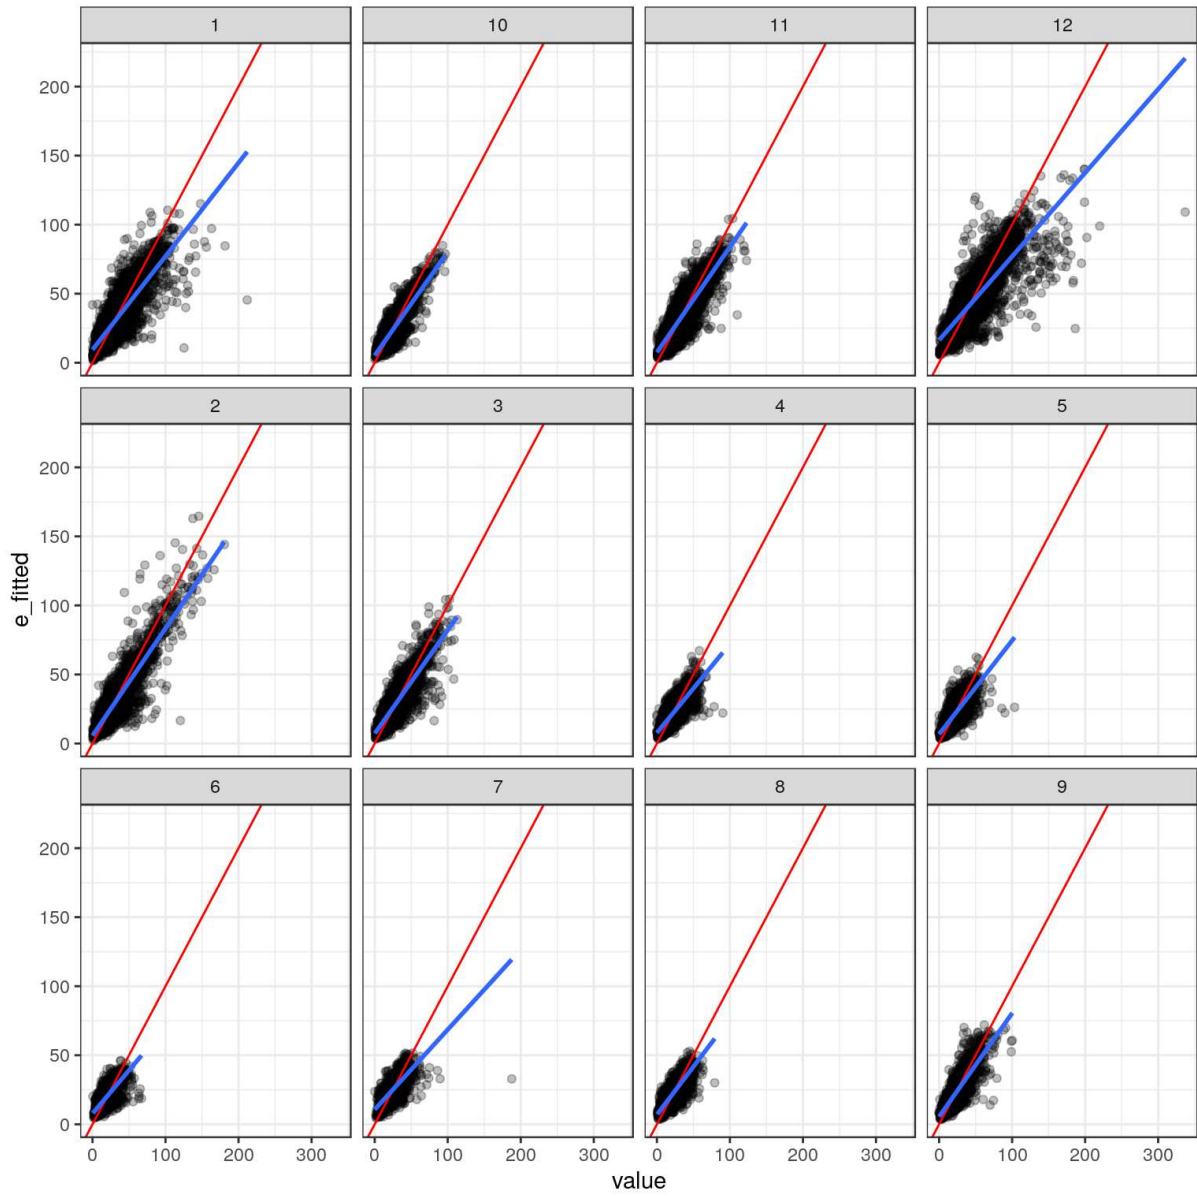
In generale, i modelli mostrano un'ottima performance in entrambe le fasi di training e di validazione.

I valori di RMSE sono più alti nei mesi invernali per entrambe le fasi. Questo non è sorprendente poiché in inverno tipicamente le concentrazioni di particolato sono più elevate.

Gli alti valori dei coefficienti di correlazione (sopra 0,9 per tutti mesi in fase di training e superiori a 0,7 in fase di validazione) mostrano che i valori previsti e quelli osservati sono in buon accordo.

Questo è illustrato anche dalla Figura 4.3 dove sono riportati i grafici di dispersione per ciascun mese dell'anno.

Fig 4.3 - Accordo tra le concentrazioni di PM<sub>10</sub> stimate dal modello e quelle misurate. Esempio anno 2015.



Fonte: ISPRA

## 5 Applicazioni

Si riportano nel seguito a titolo esemplificativo, alcune possibili usi delle simulazioni ottenute.

Si ricorda che con  $PM_{10}$  si intende la concentrazione di massa del particolato selezionato in base al diametro aerodinamico mediante teste selettive con taglio a  $10\ \mu m$  che comprende tutte le particelle con diametro aerodinamico inferiore a  $10\ \mu m$ .

Negli esempi riportati i valori stimati sono confrontati con i valori limite di legge previsti dal D.Lgs 155/2010 e con i valori guida dell'OMS (questi ultimi sono generalmente utilizzati negli studi di valutazione dell'esposizione).

**Tab 5.1 -  $PM_{10}$  - Valori limite ai sensi del D.Lgs.155/2010**

Periodo di mediazione	Valore limite D.Lgs.155/2010
1 giorno	50 $\mu g/m^3$ da non superare più di 35 volte per anno civile
Anno civile	40 $\mu g/m^3$

Fonte: D.Lgs.155/2010

**Tab 5.2 -  $PM_{10}$  - valori guida OMS ( $\mu g/m^3$ ) e interim target (IT).**

Periodo di mediazione	IT 1	IT2	IT3	IT4	AQG
Annuale	70	50	30	20	15
24 ore <sup>(a)</sup>	150	100	75	50	45

(a) 99° percentile delle medie giornaliere in un anno civile. Fonte: WHO, 2021.

L'obiettivo generale delle linee guida globali aggiornate dell'OMS (WHO, 2021) è quello di offrire raccomandazioni quantitative, basate su evidenze consolidate, circa gli effetti sulla salute dell'esposizione, per la gestione della qualità dell'aria, espresse come concentrazioni a lungo o a breve termine per una serie di inquinanti atmosferici chiave. Il superamento dei livelli delle linee guida sulla qualità dell'aria (AQG) è associato a importanti rischi per la salute pubblica. Queste linee guida non sono standard giuridicamente vincolanti; tuttavia, forniscono agli Stati membri dell'OMS uno strumento basato sull'evidenza che possono utilizzare anche per informare la legislazione e la politica. In definitiva, l'obiettivo di queste linee guida è fornire una guida per aiutare a ridurre i livelli degli inquinanti atmosferici al fine di mitigare l'enorme onere sanitario derivante dall'esposizione all'inquinamento atmosferico in tutto il mondo.

Nell'ultima revisione delle Linee Guida della Qualità dell'Aria, l'OMS ha prodotto delle stime numeriche di rischio per una serie di effetti sanitari associati ad un incremento di  $10\ \mu g/m^3$  della concentrazione media annuale per il  $PM_{10}$  ed il  $PM_{2.5}$ . Nelle sue valutazioni l'OMS non stabilisce un valore al di sotto del quale non vi sia rischio, ma individua come limite inferiore (AQG) per la media annuale il valore di  $15\ \mu g/m^3$  per il  $PM_{10}$ . Un livello AQG a lungo termine è definito come il livello di esposizione più basso a un inquinante atmosferico al di sopra del quale il *guideline development group* (GDG) è sicuro che vi sia un aumento degli effetti negativi sulla salute. I livelli Interim Target (IT) fungono da passaggi incrementali nella progressiva riduzione dell'inquinamento atmosferico verso i livelli delle linee guida sulla qualità dell'aria e sono destinati all'uso in aree in cui l'inquinamento atmosferico è elevato.

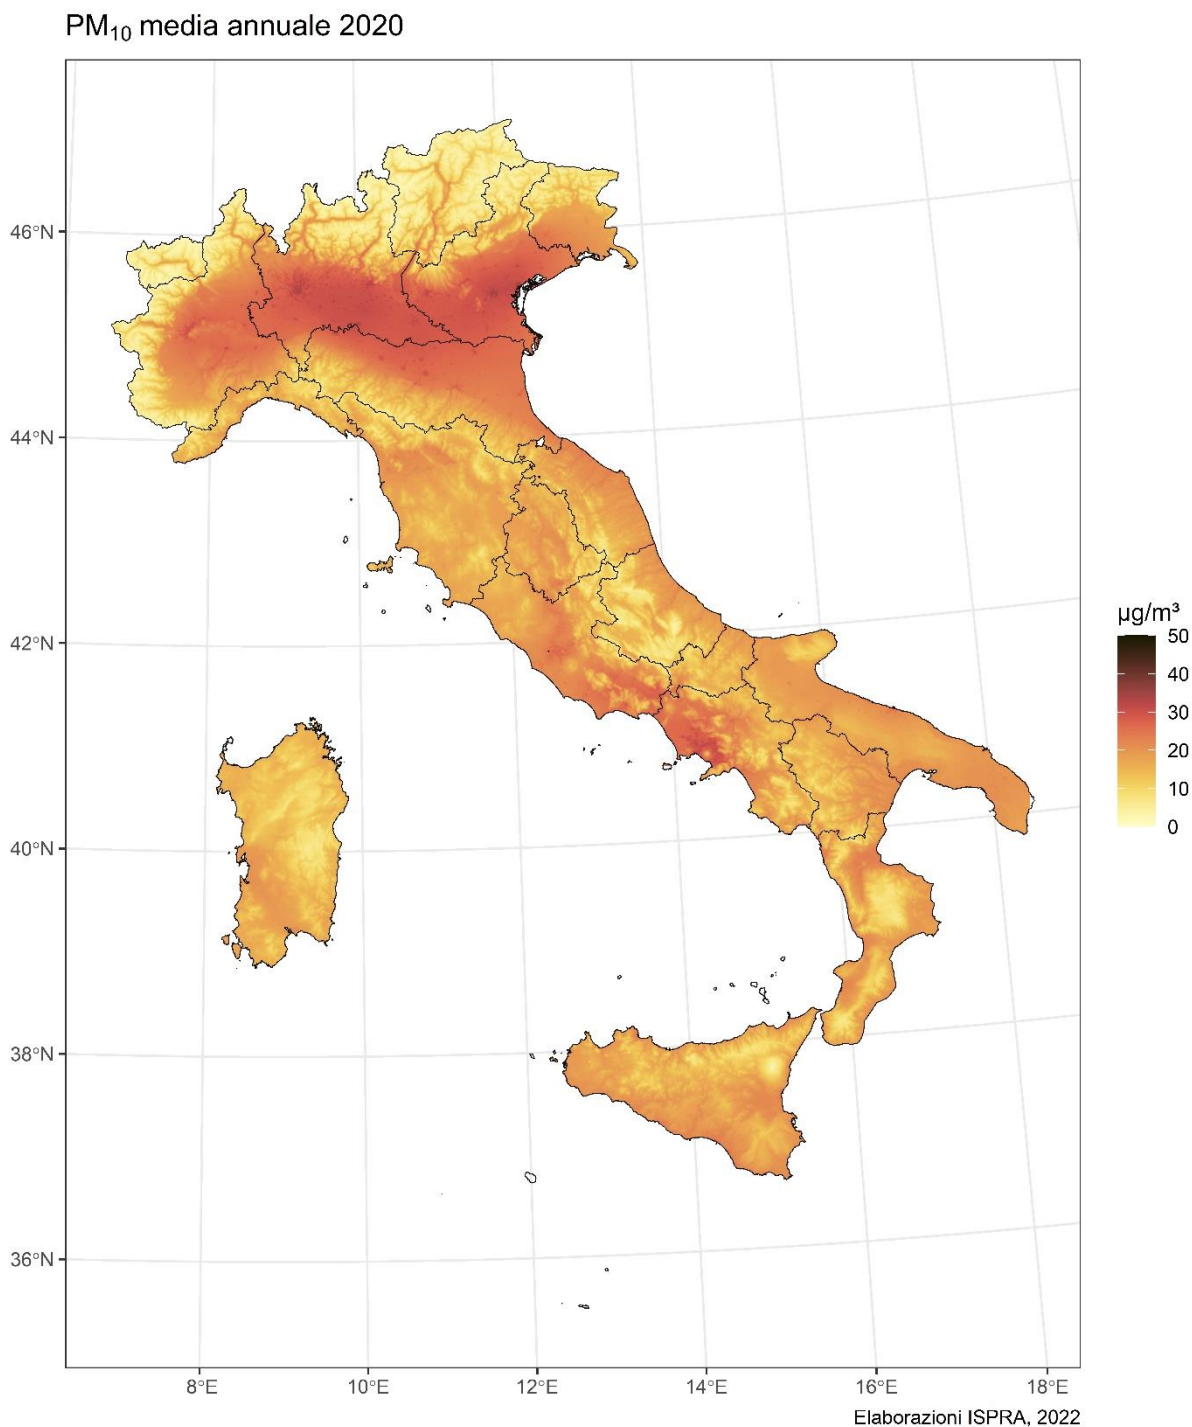
In altre parole, si tratta di livelli di inquinamento atmosferico superiori ai livelli delle linee guida sulla qualità dell'aria, ma che le autorità nelle aree altamente inquinate possono utilizzare per sviluppare politiche di riduzione dell'inquinamento realizzabili in tempi realistici. Gli obiettivi intermedi dovrebbero essere considerati come passi verso il raggiungimento finale dei livelli delle linee guida sulla qualità dell'aria, piuttosto che come obiettivi finali (OMS, 2021).

## 5.1 Stima ad alta risoluzione spaziale della concentrazione di PM<sub>10</sub> in Italia

Il più immediato esempio applicativo è quello della rappresentazione della variabilità spaziale degli indicatori che tipicamente sono utilizzati nella valutazione della qualità dell'aria.

In figura 5.1 è riportata la distribuzione ad alta risoluzione spaziale (1km x 1km) della media annuale del PM<sub>10</sub> (2020).

**Fig 5.1 - Distribuzione ad alta risoluzione spaziale (1km x 1km) della media annuale del PM<sub>10</sub> (2020).**



Fonte: Elaborazioni ISPRA, 2022

Si può apprezzare, grazie alla risoluzione spaziale delle stime, la variabilità su piccola scala delle concentrazioni di PM<sub>10</sub>: ad esempio nelle zone alpine le aree a concentrazione relativamente più elevate coincidono con le valli. Inoltre, nonostante una sostanziale omogeneità dei livelli nel bacino padano, si possono apprezzare aree di hot-



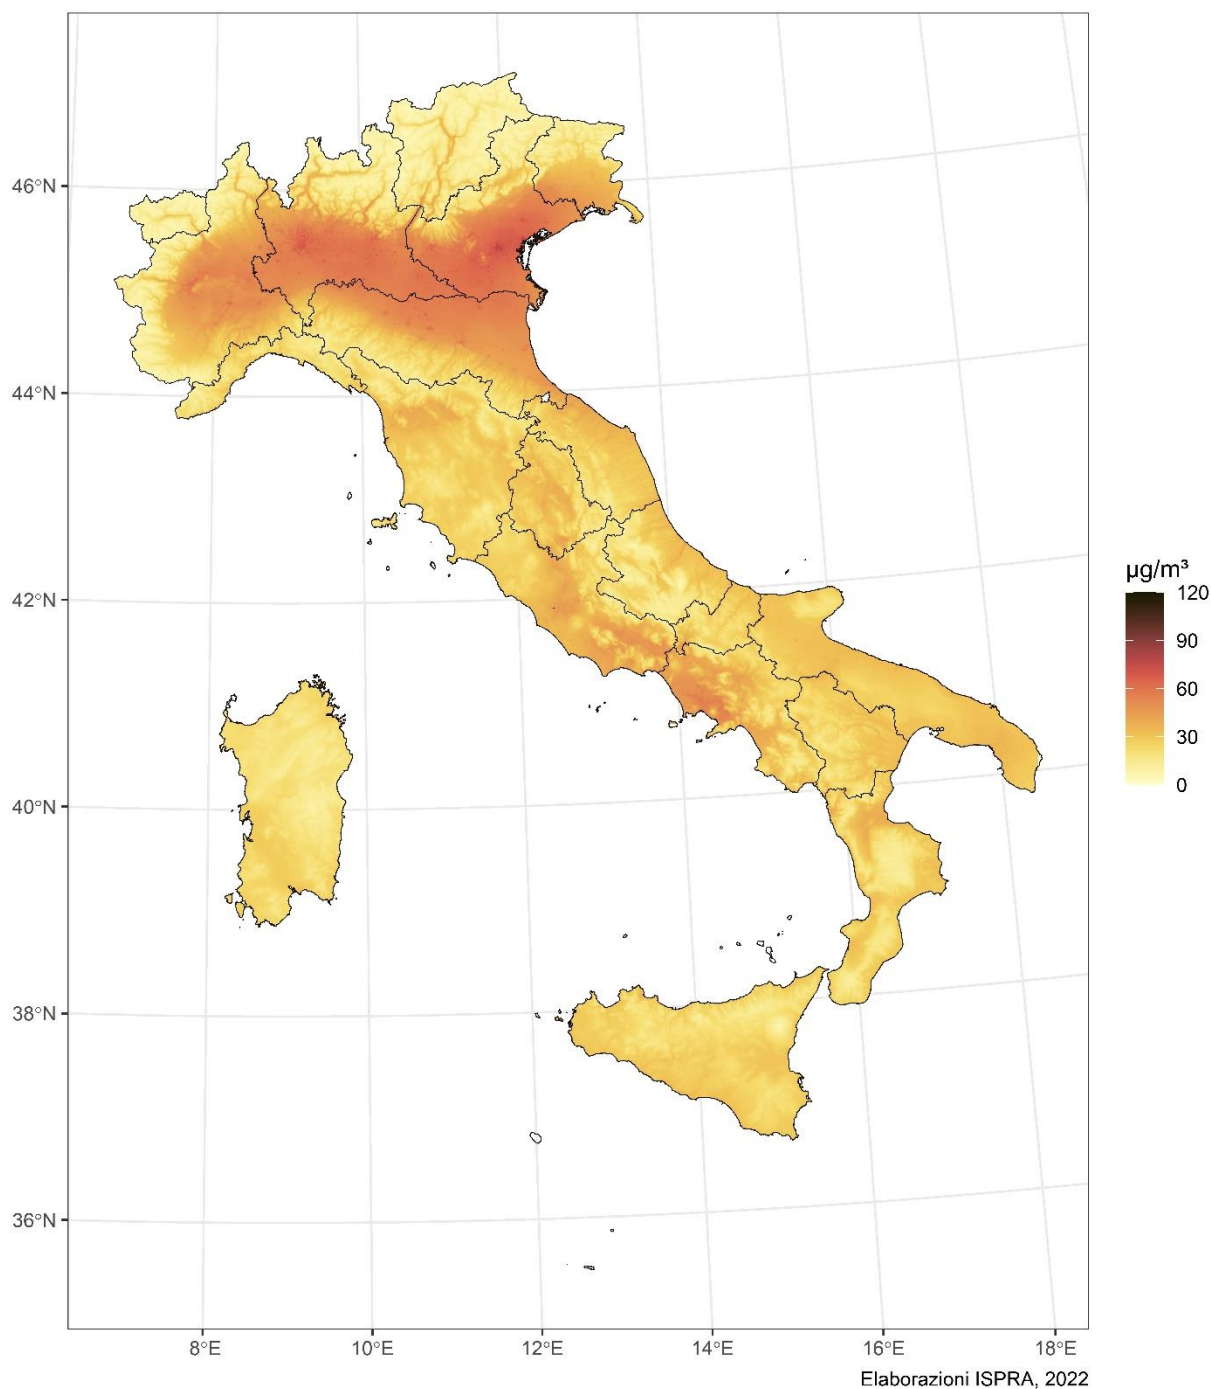
spot in corrispondenza dei grandi agglomerati urbani. Nelle zone in quota dell'arco alpino e della dorsale appenninica a bassa antropizzazione si registrano i livelli più bassi.

In figura 5.2 è riportata, a titolo di esempio per il 2020, l'analoga figura ma relativa al 90° percentile delle medie giornaliere. Il 90° percentile corrisponde al 36° valore più alto di una serie di dati giornalieri completa per un anno. Dunque quando il percentile 90° supera il valore di  $50 \mu\text{g}/\text{m}^3$  il valore limite giornaliero risulterà superato.

Entrambe le figure illustrano molto bene la variabilità spaziale dell'inquinamento da PM in Italia e l'esistenza di vaste aree dove, in particolare il valore limite giornaliero risulta non rispettato.

**Fig 5.2 – Distribuzione ad alta risoluzione spaziale (1km x 1km) del 90.4° percentile delle medie giornaliere di PM<sub>10</sub> (2020).**

PM<sub>10</sub> 2020 - 90.4° percentile delle medie giornaliere



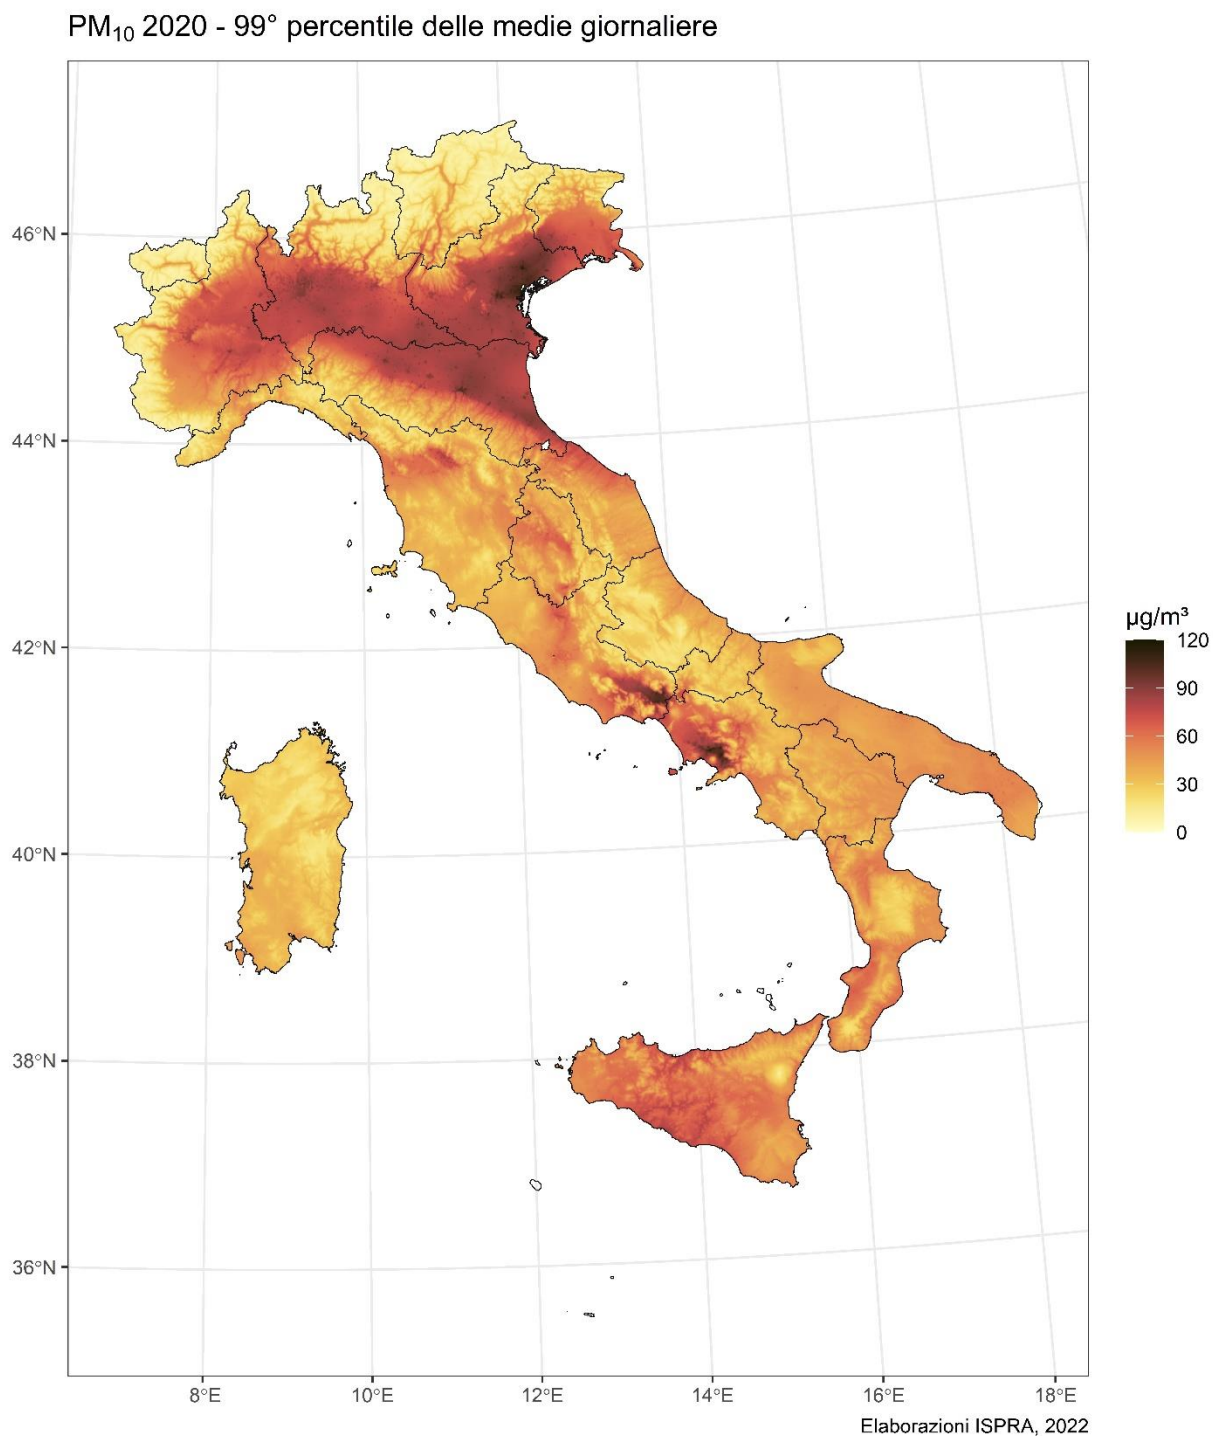
Fonte: Elaborazioni ISPRA, 2022



La figura 5.3 illustra la variabilità spaziale del percentile 99° delle medie giornaliere di PM<sub>10</sub> al 2020. Questo parametro è utile per il confronto con i valori guida e gli interim target dell'OMS descritti nell'introduzione di questo capitolo (vedi tabella 5.2).

L'utilizzo più immediato di queste simulazioni, oltre che per valutazioni di tipo descrittivo come queste, si può individuare nella valutazione dell'esposizione in studi epidemiologici. I dati finora disponibili relativi a 8 anni (2013-2020) a risoluzione temporale giornaliera e a risoluzione spaziale di 1km x 1km, o, aggregati (medie annuali, percentili) sono disponibili in formato netcdf e quindi facilmente fruibili.

**Fig 5.3 – Distribuzione ad alta risoluzione spaziale (1km x 1km) del 99° percentile delle medie giornaliere di PM<sub>10</sub> (2020).**



Fonte: Elaborazioni ISPRA, 2022

---

## 5.2 Stima delle aree di superamento

Un altro esempio delle possibili applicazioni delle stime di concentrazione di PM<sub>10</sub> ad alta risoluzione spaziale e risoluzione giornaliera prodotte per gli anni dal 2013 al 2020 è quello della stima delle "aree di superamento".

La valutazione della qualità dell'aria è organizzata in base alla zonizzazione del territorio ed alla successiva classificazione delle zone e degli agglomerati. Come riportato nel D.Lgs. 155/2010 (Art. 1) "La zonizzazione dell'intero territorio nazionale è il presupposto su cui si organizza l'attività di valutazione della qualità dell'aria ambiente. A seguito della zonizzazione del territorio, ciascuna zona o agglomerato è classificata allo scopo di individuare le modalità di valutazione mediante misurazioni e mediante altre tecniche in conformità alle disposizioni del presente decreto".

I criteri da seguire per la suddivisione del territorio in zone e agglomerati, sono indicati nell'Appendice I "Criteri per la zonizzazione del territorio" del D.Lgs. 155/2010.

La zonizzazione va riesaminata se variano i presupposti su cui si è basata.

La zonizzazione del territorio, secondo il D.Lgs. 155/2010 (Art. 1 comma d) richiede in primo luogo l'individuazione degli agglomerati e successivamente quella delle altre zone:

- gli agglomerati sono individuati sulla base dell'assetto urbanistico, della popolazione residente e della densità abitativa;

- le altre zone sono individuate, principalmente, sulla base di aspetti come il carico emissivo, le caratteristiche orografiche, le caratteristiche meteo-climatiche e il grado di urbanizzazione del territorio, al fine di individuare le aree in cui uno o più di tali aspetti sono predominanti nel determinare i livelli degli inquinanti e di accorpare tali aree in zone contraddistinte dall'omogeneità degli aspetti predominanti.

All'interno di ciascuna zona, ogni anno, occorre valutare la qualità dell'aria e adottare, in caso di superamento dei valori limite dei piani di risanamento della qualità dell'aria, seguendo precisi criteri.

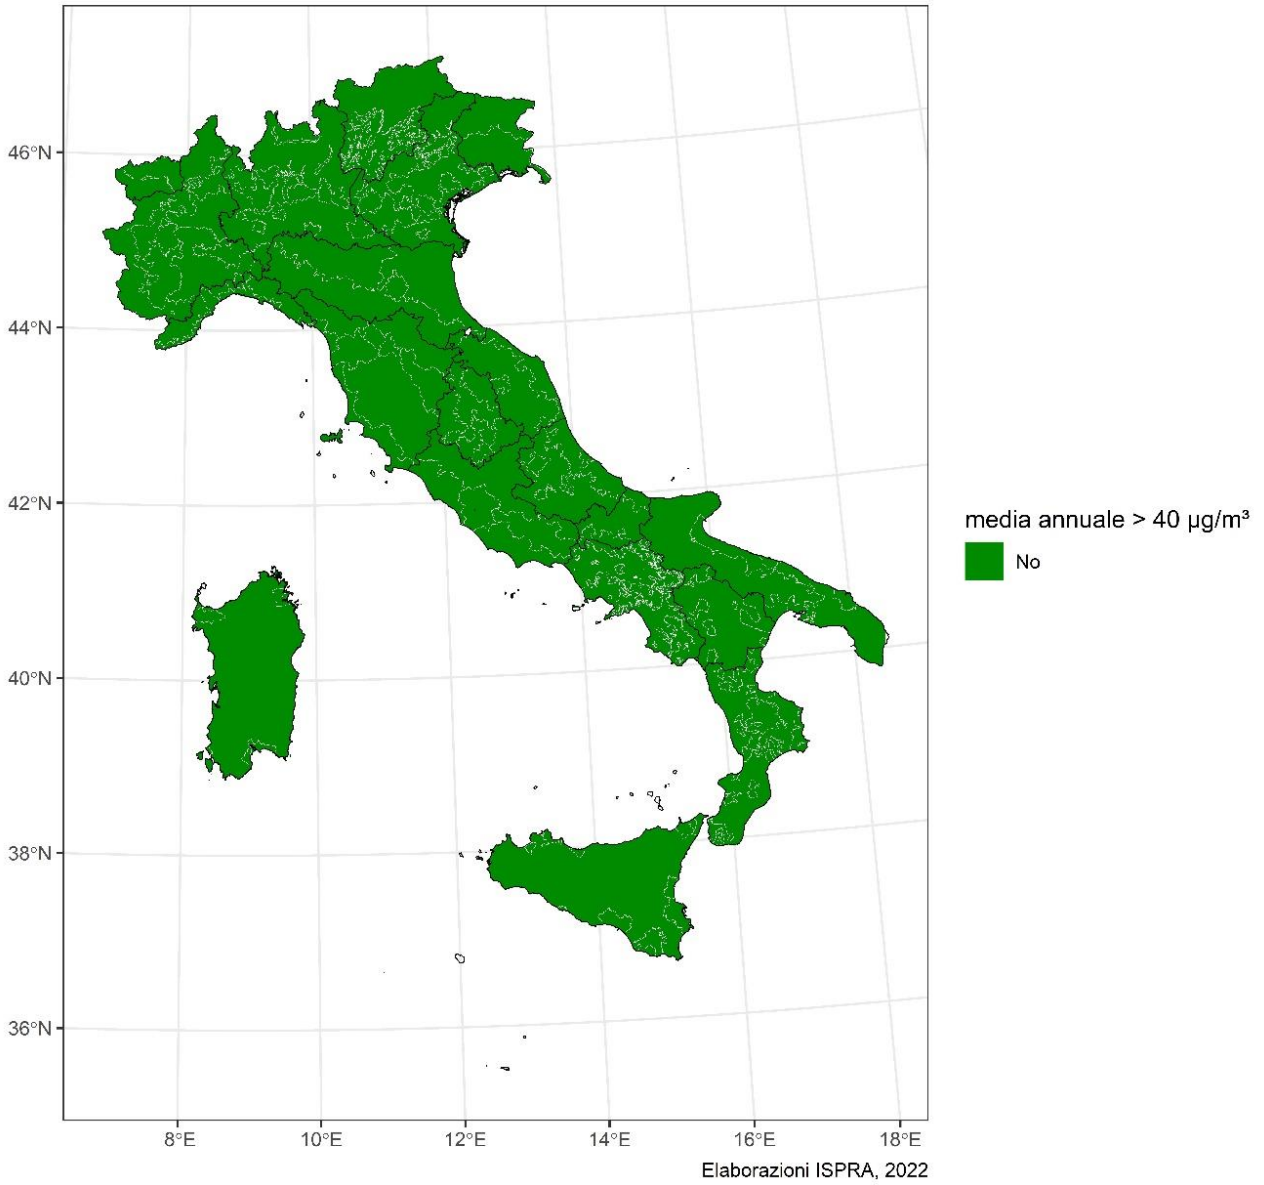
In mancanza di strumenti utili a valutare la qualità dell'aria su tutto il territorio, conservativamente, è sufficiente che una sola delle stazioni di misura presenti nel territorio della zona superi il valore limite, perché l'intera zona sia considerata in superamento. Poter individuare mediante uno strumento modellistico affidabile le aree e la percentuale di territorio della zona in superamento è importante ai fini dell'implementazione delle azioni di risanamento necessarie, con interventi mirati.

Molte Regioni hanno sviluppato e utilizzano stime modellistiche per la valutazione delle aree di superamento all'interno delle zone definite ai fini della valutazione della qualità dell'aria. Gli strumenti come questo su scala nazionale possono essere complementari e non sostitutivi degli strumenti esistenti. Laddove invece non sono disponibili stime modellistiche su scala regionale potrebbero diventare uno strumento di lavoro a supporto delle valutazioni.

A scopo illustrativo è riportata in figura 5.4 l'analisi delle aree di superamento del valore limite annuale del PM<sub>10</sub> nel 2020 (40 µg/m<sup>3</sup>). Dalle stime ottenute con il modello descritto in questo report, risulta che nel dominio di studio, la concentrazione media annuale di PM<sub>10</sub> non avrebbe mai superato la soglia di 40 µg/m<sup>3</sup>. Questo è in buon accordo con quanto rilevato dalla quasi totalità delle stazioni di monitoraggio con serie di dati con copertura temporale sufficiente per la verifica dei valori di riferimento (517 stazioni su 519; livelli compresi tra 5 e 39 µg/m<sup>3</sup>). Solo due stazioni nell'agglomerato di Napoli e Caserta, tuttavia, mostrano valori medi annuali superiori a 40 µg/m<sup>3</sup>.

**Fig 5.4 – Analisi delle aree di superamento del valore limite annuale del PM<sub>10</sub> (2020). In bianco nella mappa i confini delle zone individuate dalle Regioni ai fini della valutazione della qualità dell'aria ai sensi del D.Lgs 155/2010.**

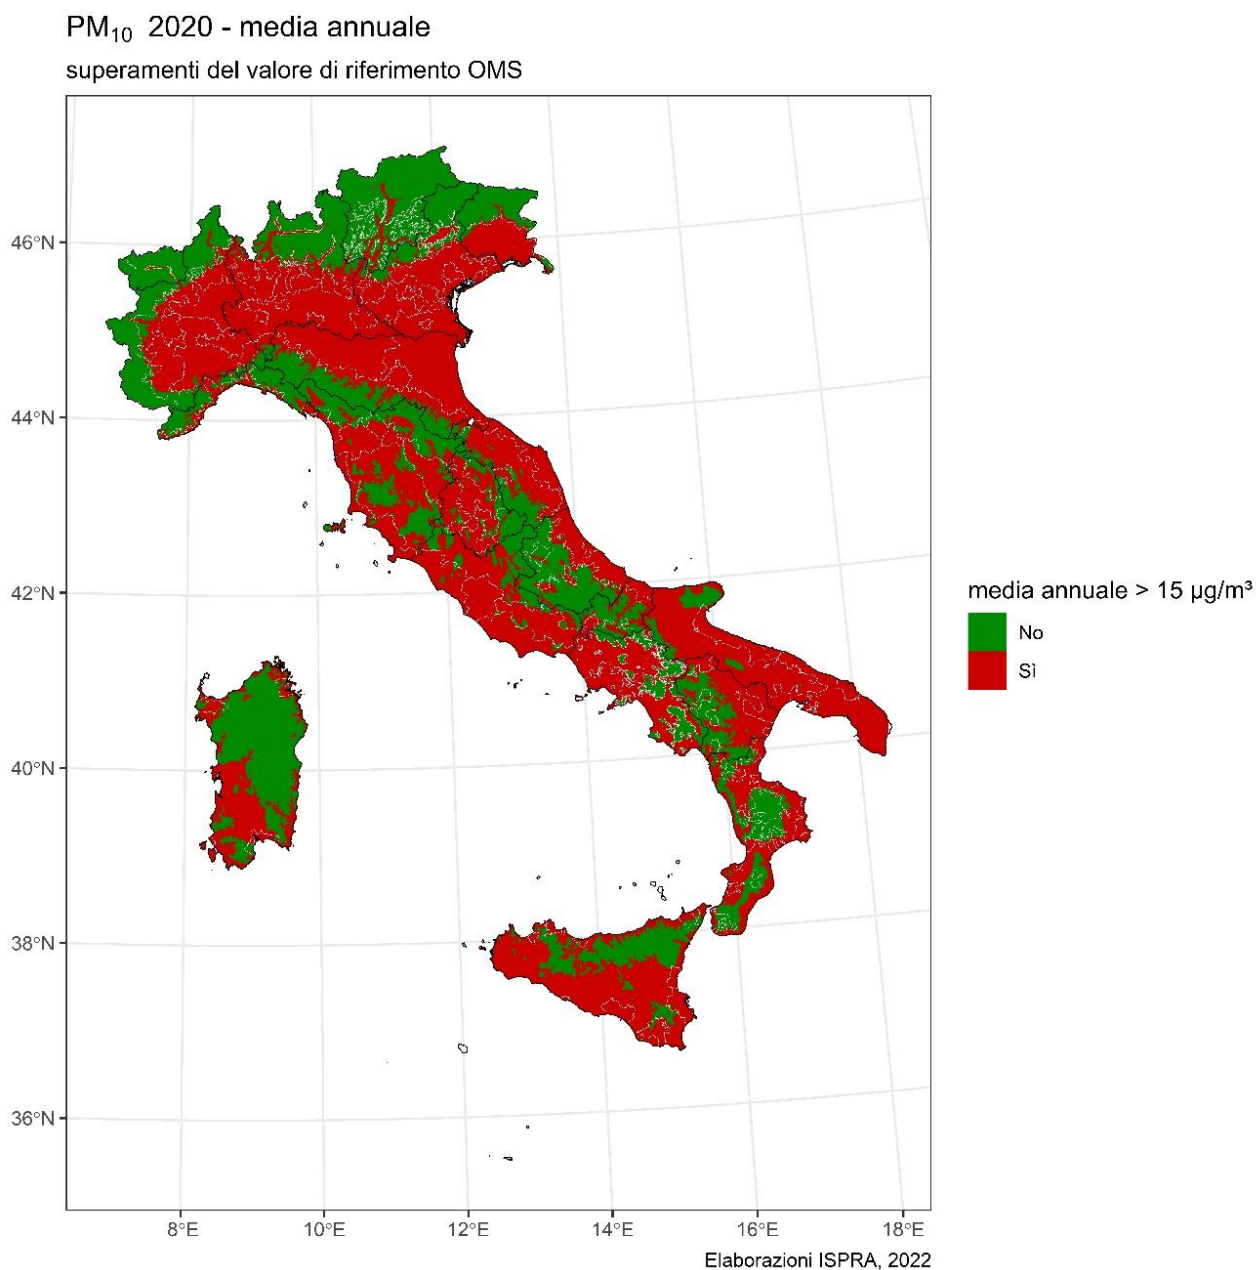
PM<sub>10</sub> 2020 - media annuale  
superamenti del valore limite di legge



Fonte: Elaborazioni ISPRA, 2022

In figura 5.5 è riportata l'analoga mappa con riferimento alle aree (in rosso) dove è superato il valore guida dell'OMS per l'esposizione a lungo termine (media annuale superiore a  $15 \mu\text{g}/\text{m}^3$ ). La presenza di vaste aree in cui i livelli medi annuali di  $\text{PM}_{10}$  sono superiori al valore guida, situazione che accomuna tutte le regioni di Italia, mette in luce la mancanza di coerenza tra gli attuali limiti di legge e i nuovi valori guida dell'OMS.

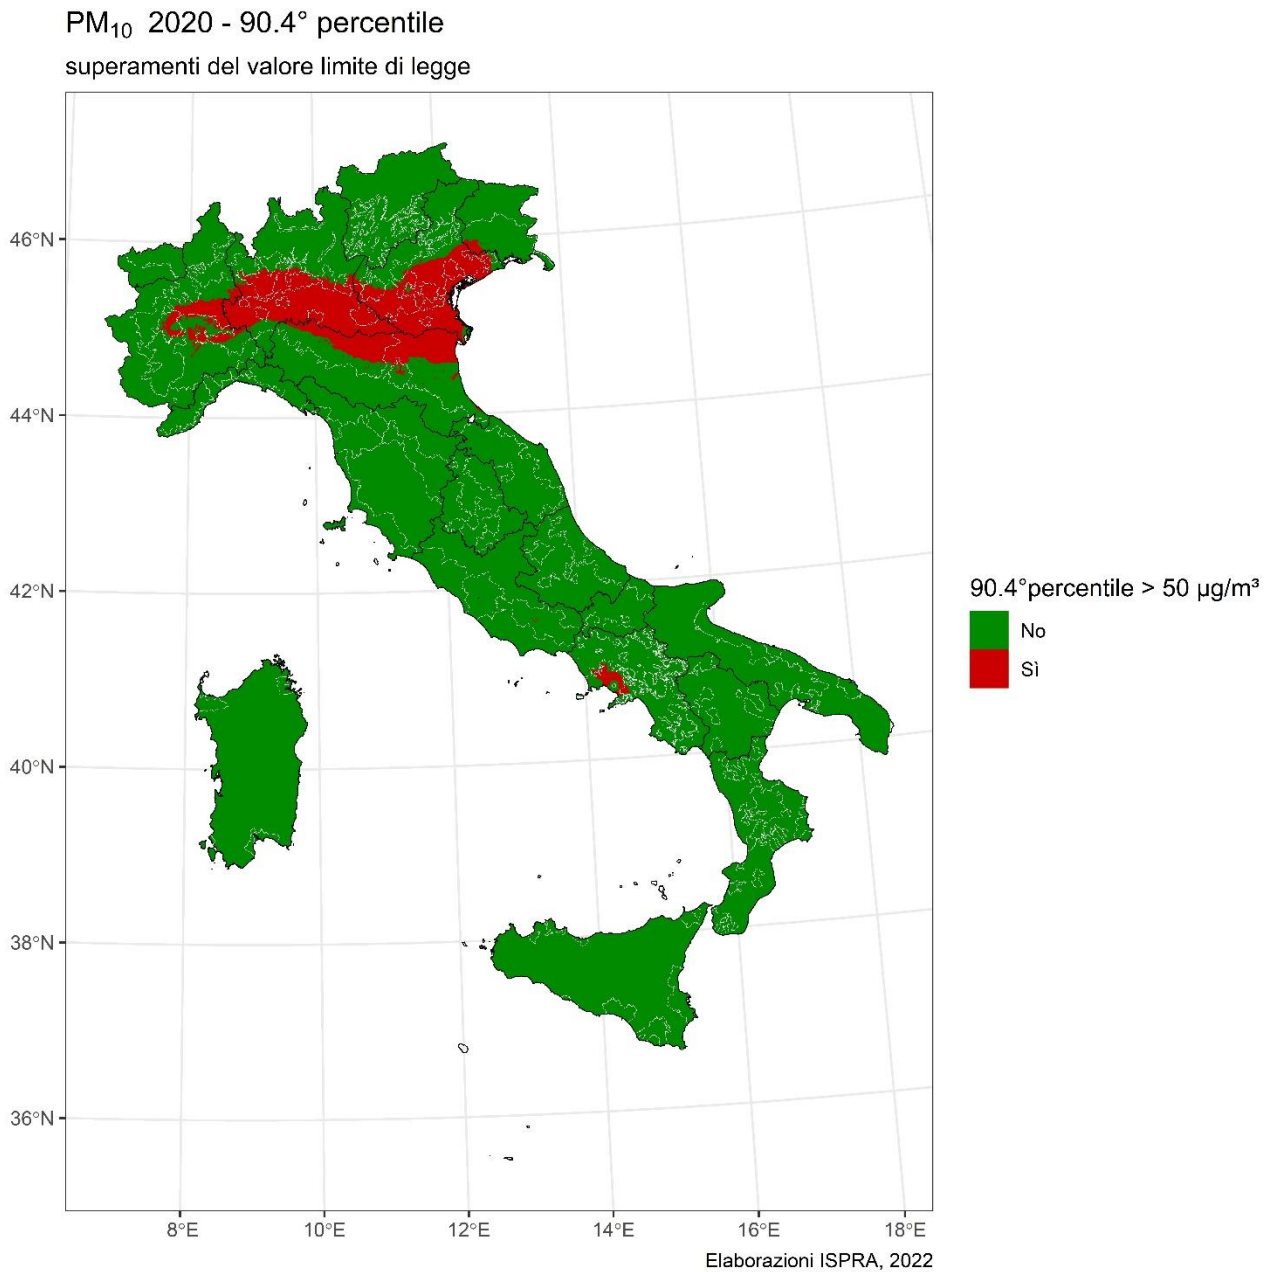
**Fig 5.5 - Analisi delle aree di superamento del valore guida per l'esposizione a lungo termine al  $\text{PM}_{10}$  (2020). In bianco nella mappa i confini delle zone individuate dalle Regioni ai fini della valutazione della qualità dell'aria ai sensi del D.Lgs 155/2010.**



Fonte: Elaborazioni ISPRA, 2022

La figura 5.6 illustra le aree di superamento del valore limite giornaliero del PM<sub>10</sub> nel 2020 (90° percentile maggiore di 50 µg/m<sup>3</sup>). Si può notare la vasta e continua area di superamento coincidente con il bacino padano. Le altre aree critiche sono evidenziabili nella zona dell'agglomerato di Napoli e Caserta, e nella zona della Valle del Sacco (Lazio meridionale).

**Fig 5.6 – Analisi delle aree di superamento del valore limite giornaliero del PM<sub>10</sub> (2020). In bianco nella mappa i confini delle zone individuate dalle Regioni ai fini della valutazione della qualità dell'aria ai sensi del D.Lgs 155/2010.**

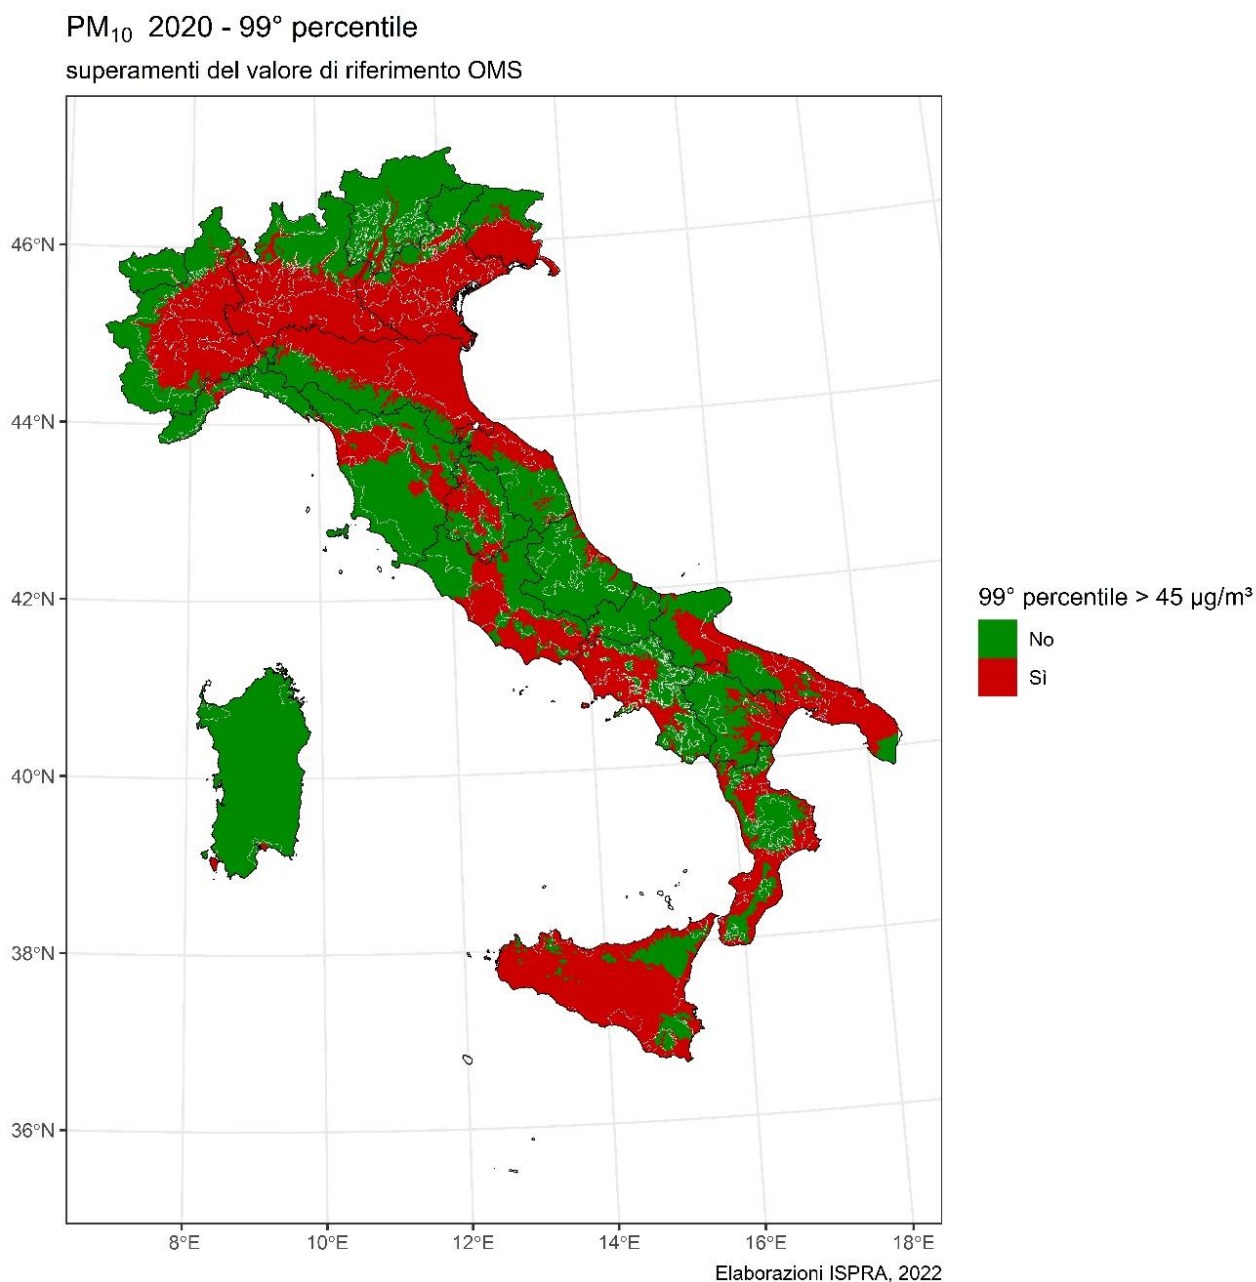


Fonte: Elaborazioni ISPRA, 2022

Come ci si poteva aspettare, il valore guida OMS per le medie giornaliere ( $45 \mu\text{g}/\text{m}^3$  per il 99° percentile) è estremamente difficile da rispettare. Sono sufficienti per il suo superamento due o tre giorni l'anno con concentrazioni superiori alla soglia individuata ( $45 \mu\text{g}/\text{m}^3$  per il 99° percentile).

Con le condizioni di stagnazione atmosferica che caratterizzano molte parti del territorio nazionale nel periodo invernale e la numerosità media degli eventi di intrusione al suolo di sabbia desertica che interessano l'intera penisola e in particolare il centro-sud ogni anno, è estremamente improbabile, anche in presenza di una significativa riduzione delle emissioni dirette e indirette di particolato, che tale valore guida sia rispettato, anche nel lungo termine, su tutto il territorio nazionale.

**Fig 5.7 – Analisi delle aree di superamento del valore guida OMS giornaliero del  $\text{PM}_{10}$  (2020).**





### 5.3 Esposizione della popolazione

Lo stato e il trend dell'inquinamento atmosferico rientrano tra gli indicatori di sviluppo sostenibile, in particolare per il fatto che le fonti di inquinamento atmosferico producono anche inquinanti che modificano il clima (es. CO<sub>2</sub> o black carbon). Stime affidabili dell'esposizione e degli impatti degli inquinanti atmosferici sono fondamentali per informare meglio i decisori politici, per monitorare i progressi nel miglioramento della qualità dell'aria e per aiutare a valutare l'efficacia delle politiche mirate alla riduzione dell'inquinamento atmosferico, nonché alla valutazione di quanto queste stiano contribuendo a proteggere la salute dei cittadini.

Nell'ambito del monitoraggio dei progressi ottenuti a livello globale nel raggiungimento degli Obiettivi di sviluppo sostenibile (SDGs) fissati dagli stati membri delle Nazioni Unite nel 2015 (agenda 2030 per lo sviluppo sostenibile) sono popolati diversi indicatori che necessitano di stime dei livelli di inquinamento atmosferico:

obiettivo 3 (Assicurare la salute e il benessere per tutti e per tutte le età), traguardo 3.9: Entro il 2030, ridurre sostanzialmente il numero di decessi e malattie da sostanze chimiche pericolose e da contaminazione e inquinamento dell'aria, delle acque e del suolo,

- indicatore 3.9.1: Mortalità attribuibile all'esposizione all'inquinamento atmosferico domestico e ambientale

obiettivo 11 (Rendere le città e gli insediamenti umani inclusivi, sicuri, duraturi e sostenibili), traguardo 11.6: entro il 2030, ridurre l'impatto ambientale negativo pro-capite delle città, prestando particolare attenzione alla qualità dell'aria e alla gestione dei rifiuti urbani e di altri rifiuti

- indicatore 11.6.2: esposizione media annuale al particolato atmosferico nelle città pesata per la popolazione

L'indicatore 3.9.1 è strettamente legato all'indicatore 11.6.2 in quanto le stime di mortalità attribuibile sono calcolate a partire dalle stime di esposizione.

Per stimare l'esposizione media della popolazione in un dato dominio (ad esempio un comune) è possibile calcolare l'esposizione media pesata per la popolazione (Population Weighted exposure, PWE).

Disponendo di stime di concentrazione ad alta risoluzione spaziale è possibile calcolare tale indicatore tenendo conto della variabilità spaziale delle due variabili in gioco. La formula per calcolare la PWE è la seguente:

$$PWE (PM_{10}) = \frac{\sum(p_i \times C_i)}{\sum p_i}$$

Con:

$p_i$  = numero di abitanti nella zona  $i$

$C_i$  = concentrazione media nella zona  $i$  [ $\mu\text{g}/\text{m}^3$ ]

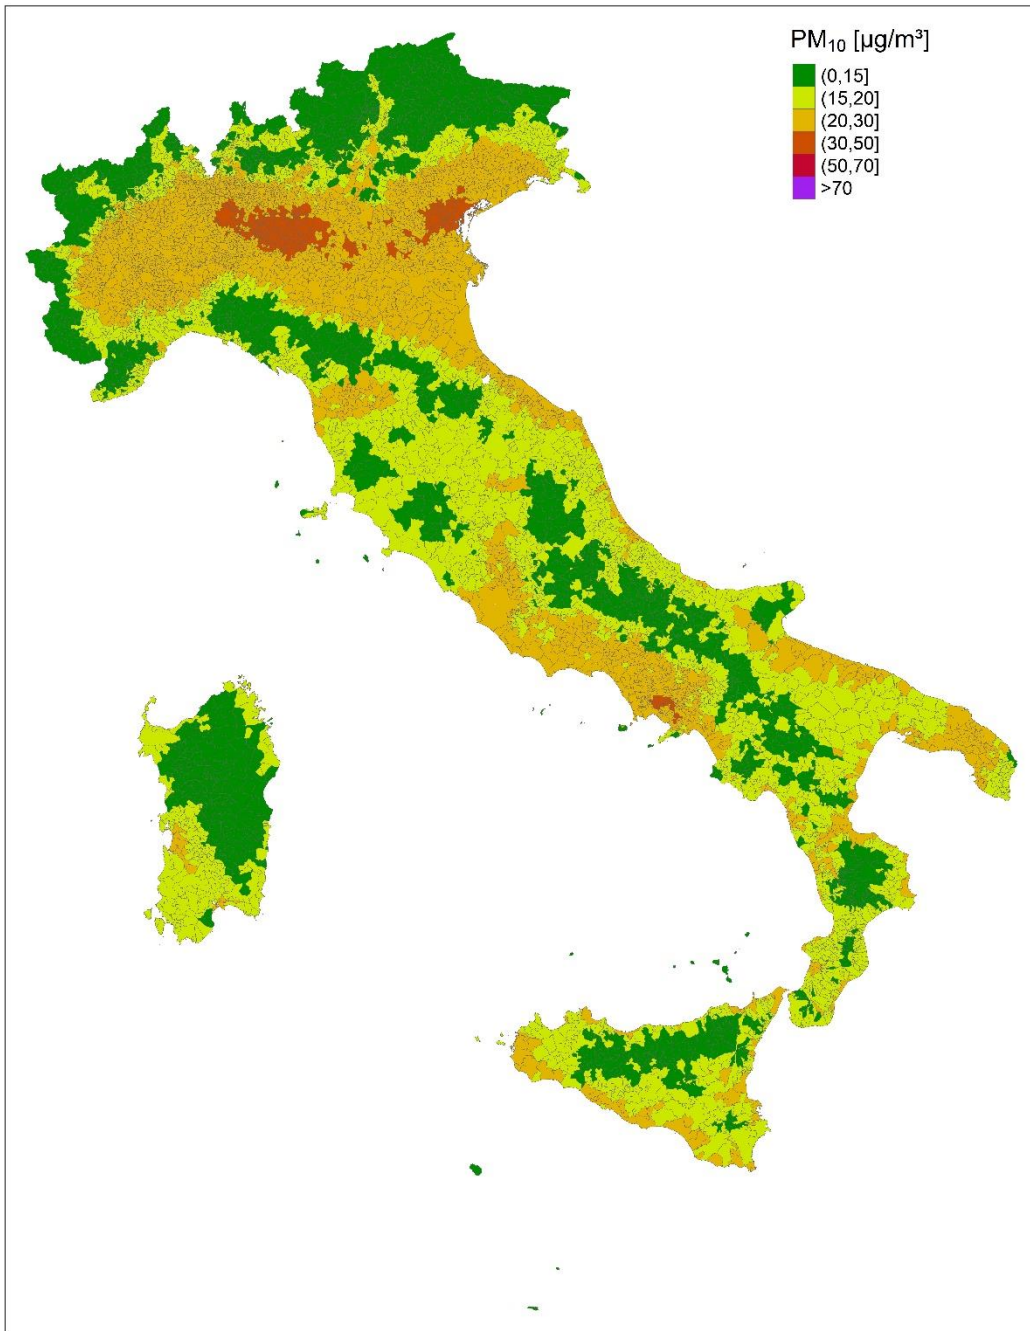
In figura 5.8 è riportato il valore della PWE al PM<sub>10</sub> su base comunale prendendo come esempio l'anno più recente disponibile (2020).

Le stime ottenute in questo modo presentano il vantaggio di poter essere estese virtualmente a tutti i comuni e non solo a quelli dove sono presenti stazioni di monitoraggio. Tradizionalmente infatti tale stime vengono fatte a partire dai dati delle stazioni di monitoraggio assumendo come valore medio di esposizione quello ottenuto mediando le concentrazioni misurate in stazioni di fondo urbano o suburbano e assumendo questa come migliore stima dell'esposizione media attribuibile alla popolazione residente in dato comune.

Il limite di un tale approccio è evidente considerato che spesso in un comune esistono singole stazioni di monitoraggio, senza contare i casi in cui non ne sia disponibile nemmeno una classificata come "fondo urbano".

I risultati delle simulazioni inoltre possono essere usati non solo per la stima dell'esposizione a lungo termine, ma anche per la stima dell'esposizione a breve termine, considerato che il modello restituisce stime su base giornaliera.

Fig 5.8 – Esposizione media al PM<sub>10</sub> pesata per la popolazione su base comunale (2020).



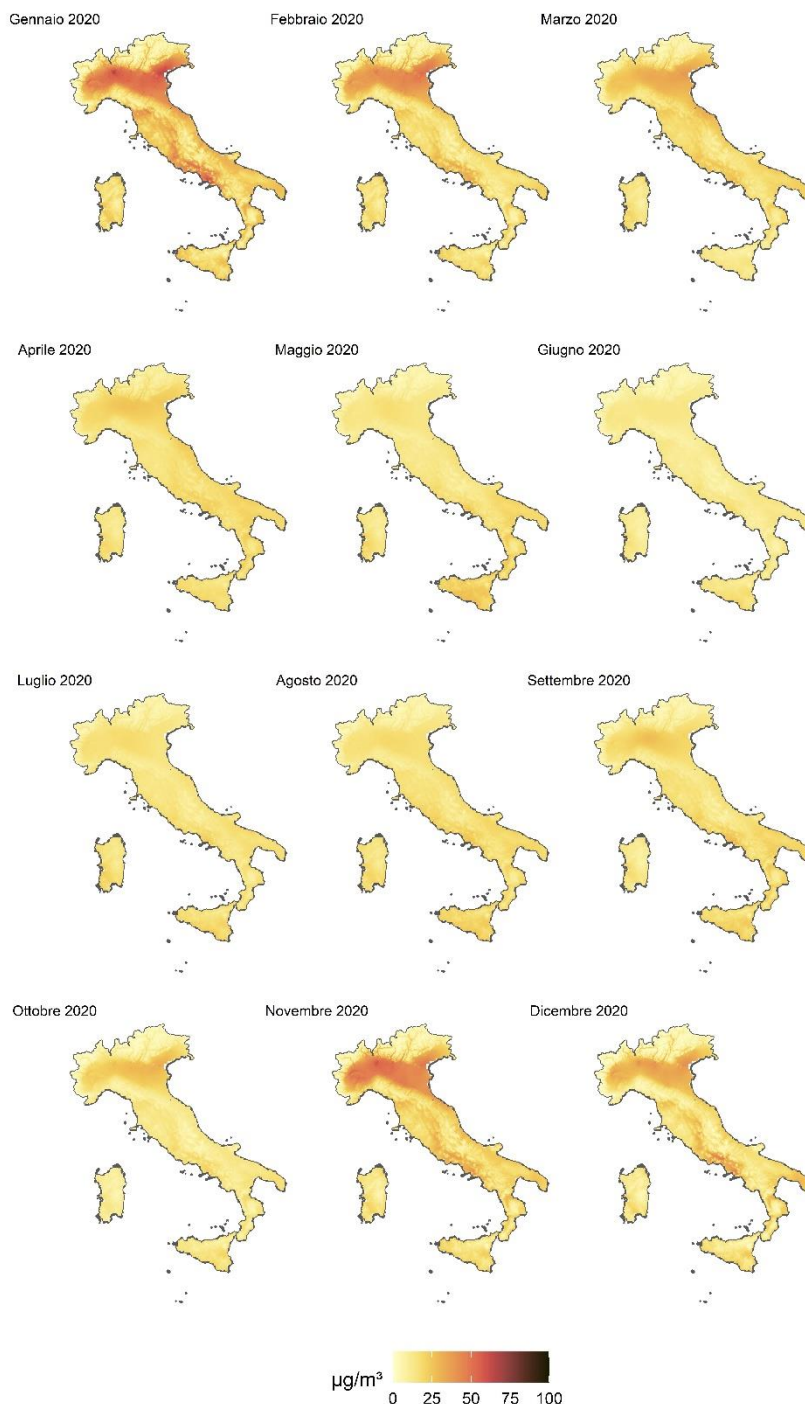
Fonte: elaborazioni ISPRA, 2022



## 5.4 Andamenti stagionali e trend nel periodo 2013 -2020

Nella figura 5.9 sono riportate le mappe relative alle medie mensili della concentrazione di PM<sub>10</sub> stimate con il modello sviluppato. A titolo di esempio sono riportate le mappe relative al 2020.

**Fig 5.9 – Stima della concentrazione media mensile del PM<sub>10</sub> (risoluzione 1km x 1km - 2020).**

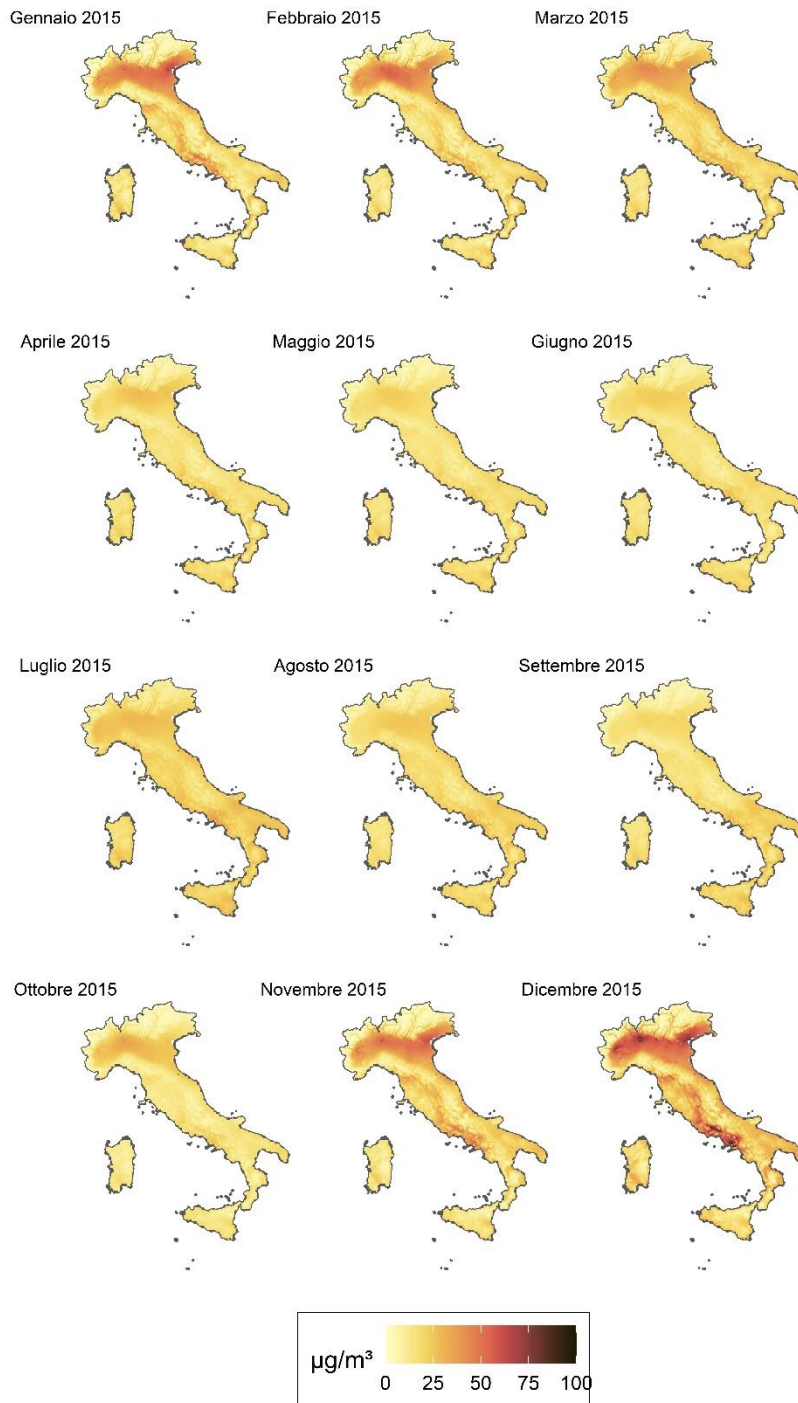


Fonte: elaborazioni ISPRA, 2022

Le mappe evidenziano la ben nota differenza tra i livelli riscontrati nei mesi invernali e quelli estivi.

Nella figura 5.10 è riportata l'analogia mappa relativa al 2015, dalla quale si può apprezzare la situazione particolarmente critica nel periodo finale dell'anno, quando si registrarono condizioni particolarmente severe di stagnazione atmosferica.

**Fig 5.10 – Stima della concentrazione media mensile del PM<sub>10</sub> (risoluzione 1km x 1km - 2015).**



Fonte: elaborazioni ISPRA, 2022

Nella figura 5.11 sono riportate le mappe relative alla media annuale stimata per ciascun anno dal 2013 al 2020. Si può apprezzare visivamente la variabilità inter-annuale e un andamento generale tendenziale di riduzione delle concentrazioni.

**Figura 5.11 – Distribuzione ad alta risoluzione spaziale (1km x 1km) della media annuale del PM<sub>10</sub> nel periodo 2013 - 2020.**

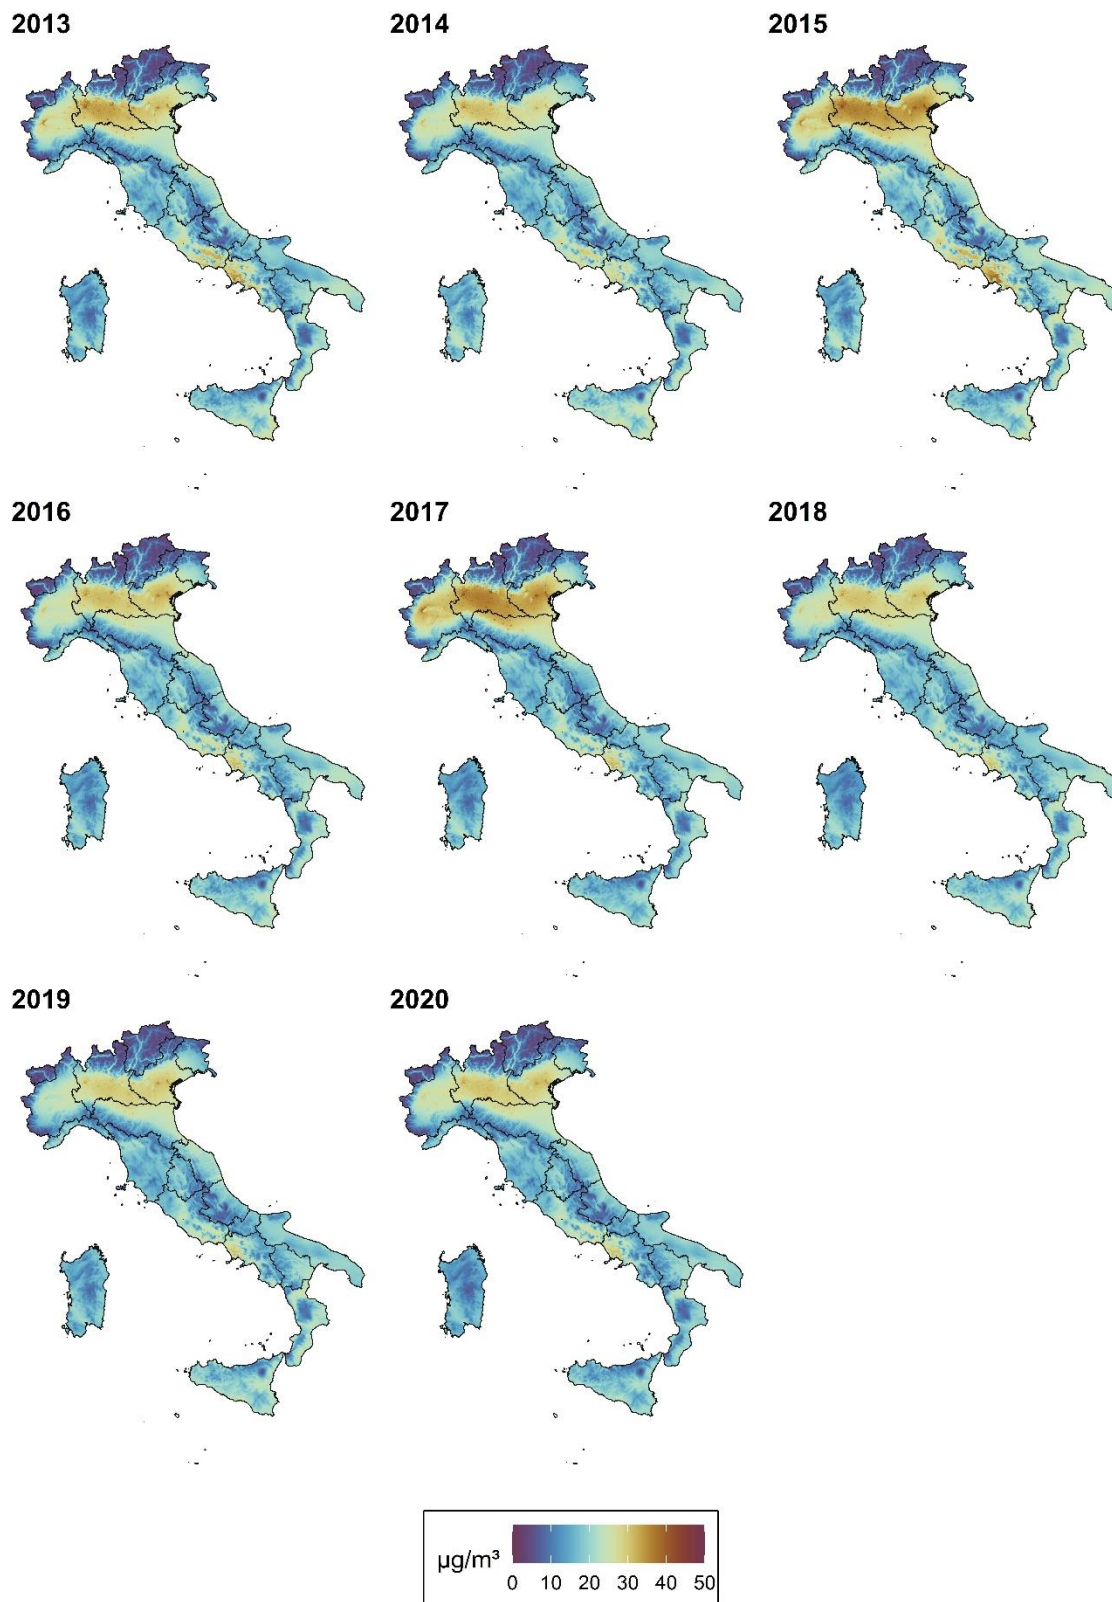



Figura 5.11 – Box plot delle medie annuali del PM<sub>10</sub> stimate (1km x 1km) nel periodo 2013 - 2020



Fonte: ISPRA

Nel periodo osservato l'anno peggiore risulta il 2015, quando, come illustrato in figura 5.10, nei mesi di novembre e dicembre le condizioni meteorologiche di stagnazione atmosferica si rivelarono particolarmente severe in molte parti del paese, senza soluzione di continuità.

La figura 5.12 illustra come i livelli medi annuali sono distribuiti. Negli ultimi 5 anni si apprezza una moderata tendenza alla riduzione dei livelli. In particolare la mediana passa da 18.1 a 17.3  $\mu\text{g}/\text{m}^3$  e resta negli ultimi due anni al di sotto dei 18  $\mu\text{g}/\text{m}^3$ . La riduzione rispetto al 2013 è pari al 3.2% nel 2019 e al 5% nel 2020.

---

## 6 Conclusioni

Abbiamo proposto in questo rapporto l'applicazione di un modello spazio-temporale gerarchico Bayesiano per la stima ad alta risoluzione spaziale (1km x 1km) delle concentrazioni giornaliere di PM<sub>10</sub> già sviluppato e validato al fine di dare una panoramica dimostrativa delle possibili applicazioni. Il modello è stato applicato, separatamente per ogni mese, alle concentrazioni di PM<sub>10</sub> misurate nel periodo 2013 - 2020 dalla rete di monitoraggio italiana.

Questo approccio rappresenta una soluzione di modellazione efficace che consente di cogliere la variabilità stagionale del fenomeno mantenendo al contempo bassi i costi computazionali. Tale strategia inoltre permette di valutare come la relazione tra i predittori considerati e le concentrazioni di PM<sub>10</sub> cambiano nel corso dei mesi.

I risultati, che confermano quanto osservato nella prima applicazione originale relativa al 2015, indicano che le covariate con gli effetti stagionali più pronunciati sono la temperatura, l'altezza dello strato limite planetario, la quota e la percentuale di superficie impervia. Anche lo spessore ottico dell'aerosol risulta una variabile significativa nello spiegare la variabilità delle concentrazioni di PM<sub>10</sub>.

Dall'insieme più ampio di potenziali predittori, descritti nel paragrafo 2.3, ne sono stati selezionati undici per la loro significatività statistica. Inoltre, tale selezione è supportata dall'analisi dei residui dei modelli che appaiono non correlati sia nello spazio che nel tempo.

Le possibili applicazioni descritte nel capitolo 5 hanno lo scopo di mostrare le potenzialità di questo tipo di modelli. Strumenti come questi, che consentono di stimare le concentrazioni al suolo degli inquinanti atmosferici ad alta risoluzione spaziale, in modo omogeneo e affidabile su un dominio spaziale sovraregionale, possono rappresentare un'interessante integrazione agli strumenti modellistici già disponibili e utilizzati di routine nelle valutazioni di qualità dell'aria, nelle stime di esposizione della popolazione e nelle stime di effetto sanitario che si possono realizzare a partire da queste.

L'estensione di questo approccio ad altri inquinanti di interesse come PM<sub>2,5</sub>, NO<sub>2</sub> e O<sub>3</sub> e lo sviluppo di tecniche di data-fusion con modelli deterministici a partire dall'approccio statistico proposto rappresentano gli sviluppi futuri di questa promettente tecnica.

A questo proposito, i risultati di Schneider et al. (2020) suggeriscono che l'introduzione tra i possibili predittori degli output di modelli chimici di trasporto potrebbero portare a un ulteriore miglioramento delle performance predittive dei modelli statistici sviluppati.

---

## 7 Bibliografia

- American Council for an Energy-Efficient Economy (ACEEE), 2018 - The 2018 International Energy Efficiency Scorecard. <http://aceee.org/research-report/i1801>
- Ang B.W., 2005. The LMDI approach to decomposition analysis: a practical guide. *Energy Policy* 33, 867–871.
- Ang B.W., Zhang F.Q., 2000. A survey of index decomposition analysis in energy and environmental studies. *Energy* 25, 1149–1176.
- Al-Hamdan, M.Z., Crosson, W.L., Limaye, A.S., Rickman, D.L., Quattrochi, M.G., Estes Jr., D.A., Qualters, J.R., Sinclair, A.H., Tolsma, D.D., Adeniyi, K.A., Niskar, A. S., 2009. Methods for characterizing fine particulate matter using ground observations and remotely sensed data: potential use for environmental public health surveillance. *J. Air Waste Manag. Assoc.* 59, 865–881.
- Attarchi, S., 2020. Extracting impervious surfaces from full polarimetric sar images in different urban areas. *Int. J. Rem. Sens.* 41, 4644–4663.
- Bakka, H., Rue, H., Fuglstad, G.-A., Riebler, A., Bolin, D., Illian, J., Krainski, E., Simpson, D., Lindgren, F., 2018. Spatial Modeling with R-INLA: a Review. *Wiley Interdiscip Rev Comput Stat.*
- Barmpadimos, I., Keller, J., Oderbolz, D., Hueglin, C., Prevot, A.S.H., 2012. One decade of parallel fine (PM<sub>2.5</sub>) and coarse (PM<sub>10</sub>–PM<sub>2.5</sub>) particulate matter measurements in europe: trends and variability. *Atmos. Chem. Phys.* 12, 3189–3203.
- Barnaba, F., Bolignano, A., Di Liberto, L., Morelli, M., Lucarelli, F., Nava, S., Perrino, C., Canepari, S., Basart, S., Costabile, F., Dionisi, D., Ciampichetti, S., Sozzi, R., Gobbi, G.P., 2017. Desert dust contribution to PM<sub>10</sub> loads in Italy: methods and recommendations addressing the relevant european commission guidelines in support to the air quality directive 2008/50. *Atmos. Environ.* 161, 288–305.
- Beloconi, A., Chrysoulakis, N., Lyapustin, A., Utzinger, J., Vounatsou, P., 2018. Bayesian geostatistical modelling of PM<sub>10</sub> and PM<sub>2.5</sub> surface level concentrations in Europe using high-resolution satellite-derived products. *Environ. Int.* 121, 57–70.
- Blangiardo, M., Cameletti, M., 2015. *Spatial and Spatio-Temporal Bayesian Models with R-INLA*. Wiley.
- Blangiardo, M., Cameletti, M., Baio, G., Rue, H., 2013. Spatial and spatio-temporal models with R-INLA. *Spat Spatiotemporal Epidemiol* 4, 33–49.
- Blangiardo, M., Pirani, M., Kanapka, L., Hansell, A., Fuller, G., 2019. A Hierarchical Modelling Approach to Assess Multi Pollutant Effects in Time-Series Studies. *PLOS ONE*.
- Cameletti, M., Ignaccolo, R., Bande, S., 2011. Comparing spatio-temporal models for particulate matter in Piemonte. *Environmetrics* 22, 985–996.
- Cameletti, M., Lindgren, F., Simpson, D., 2013. Spatio-temporal modeling of particulate matter concentration through the SPDE approach. *Adv Stat Anal* 97, 109–131.
- Chu, H.J., Huang, B., Lin, C.Y., 2015. Modeling the spatio-temporal heterogeneity in the PM<sub>10</sub> - PM<sub>2.5</sub> relationship. *Atmos. Environ.* 102, 176–182.
- Clark, J.S., Gelfand, A.E., 2006. *Hierarchical Modelling for the Environmental Sciences*. Oxford University Press.
- Cocchi, D., Greco, F., Trivisano, C., 2007. Hierarchical space-time modelling of PM<sub>10</sub> pollution. *Atmos. Environ.* 41, 532–542.
- Cohen, A.J., Brauer, M., Burnett, R., Anderson, H.R., Frostad, J., Estep, K., Balakrishnan, K., Brunekreef, B., Dandona, L., Dandona, R., Feigin, V., Freedman, G., Hubbell, B., Jobling, A., Kan, H., Knibbs, L., Liu, Y., Martin, R., Morawska, L., Pope, C.A., Shin, H., Straif, K., Shaddick, G., Thomas, M., van Dingenen, R., van Donkelaar, A., Vos, T., Murray, C.J.L., Forouzanfar, M.H., 2017. Estimates and 25- year trends of the global burden of disease attributable to ambient air pollution: an analysis of data from the Global Burden of Diseases study 2015. *Lancet* 389, 1907–1918.
- Cressie, N.A.C., Wikle, C.K., 2011. *Statistics for Spatio-Temporal Data*. Wiley.

- 
- Danielson, J., Gesch, D., 2011. Global Multi-Resolution Terrain Elevation Data 2010 (GMTED2010): U.S. Geological Survey Open-File Report 2011–1073. Technical Report Department of the Interior U.S. Geological Survey.
- Directive 2001/81/EC of the European Parliament and of the Council of 23 October 2001 on National Emission Ceilings for Certain Atmospheric Pollutants, 27/ 11/2001.
- EEA, 2019. Air Quality in Europe: 2019 Report. Technical Report European Environment Agency Luxembourg. EU, 2001.
- EC, 2004: CAFE Working Group on Particulate Matter. Second Position Paper on Particulate Matter. April 2004. [http://europa.eu.int/comm/environment/air/cafe/pdf/working\\_groups/2nd\\_position\\_paper\\_pm.pdf](http://europa.eu.int/comm/environment/air/cafe/pdf/working_groups/2nd_position_paper_pm.pdf). EU, 2002. Guidance on Assessment under the EU Air Quality Directives. Technical Report European Union.
- EU, 2008. Directive 2008/50/ec of the European Parliament and of the Council of 21 May 2008 on Ambient Air Quality and Cleaner Air for Europe, 11/6/2008.
- Forlani, C., Bhatt, S., Cameletti, M., Krainski, E., Blangiardo, M., 2020. A Joint Bayesian Space–Time Model to Integrate Spatially Misaligned Air Pollution Data in R-INLA. *Environmetrics*.
- Fuglstad, G.-A., Simpson, D.P., Lindgren, F., Rue, H., 2019. Constructing priors that penalize the complexity of Gaussian Random Fields. *J. Am. Stat. Assoc.* 114, 445–452.
- Galecki, A., Burzykowski, T., 2013. *Linear Mixed-Effects Models Using R*. Springer. Gilks, W., Richardson, S., Spiegelhalter, D., 1995. *Markov Chain Monte Carlo in Practice*. Chapman and Hall/CRC.
- Gomez-Rubio, V., 2020. *Bayesian Inference with INLA*. CRC Press.
- Grange, S.K., Carslaw, D.C., Lewis, A.C., Boleti, E., Hueglin, C., 2018. Random Forest meteorological normalisation models for Swiss PM<sub>10</sub> trend analysis. *Atmos. Chem. Phys.* 18, 6223–6238.
- Grisotto, L., Consonni, D., Cecconi, L., Catelan, D., Lagazio, C., Bertazzi, P.B., Baccini, M., Biggeri, A., 2016. Geostatistical integration and uncertainty in pollutant concentration surface under preferential sampling. *Geospat Health* 11, 56–61.
- Haklay, M.M., Basiouka, S., Antoniou, V., Ather, A., 2010. How many volunteers does it take to map an area well? The validity of Linus’ law to volunteered geographic information. *Cartogr. J.* 47, 315–322.
- Heaton, M.J., Datta, A., Finley, A.O., Furrer, R., Guinness, J., Guhaniyogi, R., Gerber, F., Gramacy, R.B., Hammerling, D., Katzfuss, M., Lindgren, F., Nychka, D.W., Sun, F., Zammit-Mangion, A., 2019. A case study competition among methods for analyzing large spatial data. *J. Agric. Biol. Environ. Stat.* 24, 398–425.
- Hersbach, H., Bell, B., Berrisford, P., Hirahara, S., Horányi, A., Muñoz-Sabater, J., Nicolas, J., Peubey, C., Radu, R., Schepers, D., Simmons, A., Soci, C., Abdalla, S., Abellan, X., Balsamo, G., Bechtold, P., Biavati, G., Bidlot, J., Bonavita, M., De Chiara, G., Dahlgren, P., Dee, D., Diamantakis, R., Dragani, M., Flemming, J., Forbes, R., Fuentes, M., Geer, A., Haimberger, L., Healy, S., Hogan, R., Hólm, E., Janisková, M., Keeley, S., Laloyaux, P., Lopez, P., Lupu, C., Radnoti, G., de Rosnay, P., Rozum, I., Vamborg, F., Villaume, S., Thépaut, J., 2020. The ERA5 Global Reanalysis. *Q J R Meteorol Soc.* Hidy, G.M., Brook, J.R., Chow, J.C., Green, M., Husar, R.B., Lee, C., Scheffe, R.D., Swanson, A., Watson, J.G., 2009. Remote sensing of particulate pollution from space: have we reached the promised land? *J. Air Waste Manag. Assoc.* 59, 1130–1139.
- Hoek, G., 2017. Methods for assessing long-term exposures to outdoor air pollutants. *Curr. Environ. health Rep.* 4, 450–462.
- Huang, G., Lee, D., Scott, E.M., 2018. Multivariate space-time modelling of multiple air pollutants and their health effects accounting for exposure uncertainty. *Stat. Med.* 37, 1134–1148.
- ISPRA, 2019. *Analisi dei trend dei principali inquinanti atmosferici in Italia (2008-2017)*. Technical Report ISPRA Roma.
- ISPRA, 2020. *Annuario dei Dati Ambientali - Edizione 2019*. Technical Report ISPRA Roma.
- Kloog, I., Sorek-Hamera, M., Lyapustin, A., Coull, B., Wange, Y., Just, A., Schwartz, J., Broday, D., 2015. Estimating daily PM<sub>2.5</sub> and a PM<sub>10</sub> cross the complex geo-climate region of Israel using MAIAC satellite-based aod data. *Atmos. Environ.* 122, 409–416.



- 
- Langanke, T., 2015. Outdoor Air Pollution. IARC Monographs on the Evaluation of Carcinogenic Risk to Humans. Technical Report International Agency for Research on Cancer.
- Langanke, T., 2018. Copernicus Land Monitoring Service – High Resolution Layer Imperviousness: Product Specifications Document. Technical Report EEA.
- Lindgren, F., Rue, H., Lindström, J., 2011. An explicit link between Gaussian fields and Gaussian Markov Random Fields: the stochastic partial differential equation approach. *J. Roy. Stat. Soc.: Ser. Bibliogr.* 73, 423–498.
- Liu, Y., Guoa, H., Mao, G., Yang, P., 2008. A Bayesian hierarchical model for urban air quality prediction under uncertainty. *Atmos. Environ.* 42, 8464–8469.
- Martuzzi, M., Mitis, F., Iavarone, I., Serinelli, M., 2006. Health Impact of PM<sub>10</sub> and Ozone In 13 Italian Cities. Technical Report World Health Organization Regional Office for Europe.
- Matassoni, L., Pratesi, G., Centioli, D., Cadoni, F., Malesani, P., Caricchia, A.M., Di Bucchianico, A.M., 2009. Saharan dust episodes in Italy: influence on PM<sub>10</sub> daily limit value (DLV) exceedances and the related synoptic. *Environ. Sci. Process. Impact* 11, 1586–1594.
- Ott, R.W., 1990. A physical explanation of the lognormality of pollutant concentrations. *J. Air Waste Manag. Assoc.* 40, 1378–1383.
- Perez, C., Haustein, K., Janjic, Z., Jorba, O., Huneus, N., Baldasano, J.M., Black, T., Basart, S., Nickovic, S., Miller, R.L., Perlwitz, J.P., Schulz, M., Thomson, M., 2011. Atmospheric dust modeling from meso to global scales with the online NMMB/BSCDust model; Part 1: model description, annual simulations and evaluation. *Atmos. Chem. Phys.* 11, 13001–13027.
- Perrino, C., Catrambone, M., Canepari, S., 2020. Chemical composition of PM<sub>10</sub> in 16 urban, industrial and background sites in Italy. *Atmosphere* 11.
- Pey, J., Querol, X., Alastuey, A., Forastiere, F., Stafoggia, M., 2013. African dust outbreaks over the Mediterranean Basin during 2001–2011: PM<sub>10</sub> concentrations, phenomenology and trends, and its relation with synoptic and mesoscale meteorology. *Atmos. Chem. Phys.* 13, 1395–1410.
- Pikridas, M., Vrekoussis, M., Sciare, J., Kleanthous, S., Vasiliadou, E., Kizas, C., Savvides, C., Mihalopoulos, N., 2018. Spatial and temporal (short and long term) variability of submicron, fine and sub-10 µm particulate matter (PM<sub>1</sub>, PM<sub>2.5</sub>, PM<sub>10</sub>) in Cyprus. *Atmos. Environ.* 191, 79–93.
- Pinheiro, J., Bates, D., DebRoy, S., Sarkar, D., R Core Team, 2020. nlme: Linear and Nonlinear Mixed Effects Models. R package version 3, 1–148.
- Pirani, M., Gulliver, J., Fuller, G.W., Blangiardo, M., 2014. Bayesian spatiotemporal modelling for the assessment of short-term exposure to particle pollution in urban areas. *J. Expo. Sci. Environ. Epidemiol.* 24, 319–327.
- Piscitelli, P., Valenzano, B., Rizzo, E., Maggiotto, G., Rivezzi, M., Corcione, F.E., Miani, A., 2019. Air pollution and estimated health costs related to road transportations of goods in Italy: a first healthcare burden assessment. *Int. J. Environ. Res. Publ. Health* 16.
- Plummer, M., 2016. Rjags: Bayesian Graphical Models Using MCMC. R Package Version 4-6.
- Pollice, A., Jona Lasinio, G., 2010. Spatio temporal analysis of the PM<sub>10</sub> concentration over the Taranto area. *Environ. Monit. Assess.* 162, 177–190.
- Porcu, E., Montero, J., Schlather, M., 2012. Advances and Challenges in Space-Time Modelling of Natural Events. R Core Team, 2018. R: A Language and Environment for Statistical Computing. R Foundation for Statistical Computing Vienna, Austria. URL. [www.R-project.org](http://www.R-project.org).
- Rue, H., Held, L., 2005. Gaussian Markov Random Fields: Theory and Applications. Chapman & Hall/CRC Monographs on Statistics & Applied Probability. CRC Press.
- Rue, H., Martino, S., Chopin, N., 2009. Approximate Bayesian inference for latent Gaussian models using integrated nested Laplace approximations (with discussion). *J. Royal Stat. Soc., Series B* 71, 319–392.
- Sahu, S.K., 2011. Hierarchical Bayesian models for space-time air pollution data. *Handb. Stat.* 30, 477–495.



- 
- Samoli, E., Stafoggia, M., Rodopoulou, S., Ostro, B., Declercq, C., Alessandrini, E., Díaz, J., Karanasiou, A., Kelessis, A.G., Le Tertre, A., Pandolfi, P., Randi, G., Scarinzi, C., Zauli-Sajani, S., Katsouyanni, K., Forastiere, F., the Med-Particles Study group, 2013. Associations between fine and coarse particles and mortality in Mediterranean cities: results from the MED-PARTICLES project. *Environ. Health Perspect.* 121.
- Sarafian, R., Kloog, I., Just, A.C., Rosenblatt, J.D., 2019. Gaussian Markov random fields versus linear mixed models for satellite-based PM<sub>2.5</sub> assessment: evidence from the northeastern USA. *Atmos. Environ.* 205, 30–35.
- Schneider, R., Vicedo-Cabrera, A.M., Sera, F., Masselot, P., Stafoggia, M., de Hoogh, K., Kloog, I., Reis, S., Vieno, M., Gasparrini, A., 2020. A satellite-based spatio-temporal machine learning model to reconstruct daily PM<sub>2.5</sub> concentrations across Great Britain. *Rem. Sens.* 12.
- Segura, S., Estellés, V., Utrillas, M.P., Martínez-Lozano, J., 2017. Long term analysis of the columnar and surface aerosol relationship at an urban European coastal site. *Atmos. Environ.* 167, 309–322.
- Shaddick, G., Thomas, M.L., Green, A., Brauer, M., van Donkelaar, A., Burnett, R., Chang, H.H., Cohen, A., van Dingenen, R., Dora, C., Gumy, S., Liu, Y., Martin, R., Waller, L.A., West, J., Zidek, J.V., 2017. Data integration model for air quality: a hierarchical approach to the global estimation of exposures to ambient air pollution. *J. Roy. Stat. Soc.: Series C (Applied Statistics)* 67, 231–253.
- Shahraiyini, H.T., Sodoudi, S., 2016. Statistical modeling approaches for PM<sub>10</sub> prediction in urban areas; a review of 21st-century studies. *Atmosphere* 7.
- Simpson, D.P., Rue, H., Riebler, A., Martins, T.G., Sørbye, S.H., 2017. Penalising model component complexity: a principled, practical approach to constructing priors. *Stat. Sci.* 32, 1–28.
- Spiegelhalter, D.J., Thomas, A., Best, N.G., Gilks, W.R., 1995. *Bugs: Bayesian Inference Using Gibbs Sampling version 0.50*.
- Sørbye, S.H., Rue, H., 2017. Penalised complexity priors for stationary autoregressive processes. *J Time Ser Anal* 38, 923–935.
- Stafoggia, M., Bellander, T., Bucci, S., Davoli, M., de Hoogh, K., de' Donato, F., Gariazzo, C., Lyapustin, A., Michelozzi, P., Renzi, M., Scortichini, M., Shtein, A., Viegi, G., Kloog, I., Schwartz, J., 2019. Estimation of daily PM<sub>10</sub>–PM<sub>2.5</sub> concentrations in Italy, 2013–2015, using a spatiotemporal land-use Random-forest model. *Environ. Int.* 124, 170–179.
- Stafoggia, M., Schwartz, J., Badaloni, C., Bellander, T., Alessandrini, E., Cattani, G., De' Donato, F., Gaeta, A., Leone, G., Lyapustin, A., Sorek-Hamer, M., de Hoogh, K., Di, Q., Forastiere, F., Kloog, I., 2017. Estimation of daily PM<sub>10</sub> concentrations in Italy (2006–2012) using finely resolved satellite data, land use variables and meteorology. *Environ. Int.* 99, 234–244.
- Stein, A.F., Draxler, R.R., Rolph, G.D., Stunder, B.J.B., Cohen, M.D., Ngan, F., 2015. NOAA's HYSPLIT atmospheric transport and dispersion modeling system. *Bull. Am. Meteorol. Soc.* 96, 2059–2077.
- Strobl, C., 2008. *Postgis*. In: *Encyclopedia of GIS*. Springer US, Boston, MA, pp. 891–898. Team, S.D., 2015. *Stan Modeling Language User's Guide and Reference Manual version 2.6.1*.
- Tobías, A., Pérez, L., Díaz, J., Linares, C., Pey, J., Alastruey, A., Querol, X., 2011. Short-term effects of particulate matter on total mortality during saharan dust outbreaks: a case crossover analysis in Madrid (Spain). *Sci. Total Environ.* 412–413, 386–389.
- Warsono, K.P.S., Bartolucci, A.A., Bae, S., 2001. Mathematical modeling of environmental data. *Math. Comput. Model.* 33, 793–800.
- Weber, S.A., Engel-Cox, J.A., Hoff, R.M., Prados, A.I., Zhang, H., 2010. An improved method for estimating surface fine particle concentrations using seasonally adjusted satellite aerosol optical depth. *J. Air Waste Manag. Assoc.* 60, 574–585.
- Who, 2013. *Review of Evidence on Health Aspects of Air Pollution – REVIHAAP Project*. Technical Report World Health Organization.
- WHO global air quality guidelines. Particulate matter (PM<sub>2.5</sub> and PM<sub>10</sub>), ozone, nitrogen dioxide, sulfur dioxide and carbon monoxide. Geneva: World Health Organization; 2021. Licence: CC BY-NC-SA 3.0 IGO.

---

Yang, Y., Christakos, G., Huang, W., Lin, C., Fu, P., Mei, Y., 2016. Uncertainty assessment of PM<sub>2.5</sub> contamination mapping using spatiotemporal sequential indicator simulations and multi-temporal monitoring data. *Sci. Rep.* 6.

Zhang, J., Li, B., Chen, Y., Chen, M., Fang, T., Liu, Y., 2018. Eigenvector spatial filtering regression modeling of ground PM<sub>2.5</sub> concentrations using remotely sensed data. *Int. J. Environ. Res. Publ. Health* 15.

