



Progetto PULVIRUS

Obiettivo 1 - Analisi degli effetti delle misure di distanziamento fisico durante il periodo della pandemia da COVID 19: cosa dicono le stazioni di monitoraggio italiane

ATTIVITÀ 1.4.3 - Analisi delle serie temporali di dati di qualità dell'aria con modelli Bayesiani e approccio INLA-SPDE.

Data: 31/12/2021



AUTORI

ISPRA

Guido Fioravanti, Giorgio Cattani,

NORWEGIAN UNIVERSITY OF SCIENCE AND TECHNOLOGY, TRONDHEIM, NORWAY

Sara Martino

DIPARTIMENTO DI ECONOMIA UNIVERSITÀ DI BERGAMO

Michela Cameletti

EUROPEAN COMMISSION, JOINT RESEARCH CENTRE, ISPRA, ITALY

Enrico Pisoni



SOMMARIO

1	introduzione	4
2	obiettivi	8
3	metodi	9
3.1	Siti di monitoraggio e dati di qualità dell'aria.....	9
3.2	Differenze giornaliere.....	11
3.3	Regressori spaziali e temporali.....	12
4	Sviluppo del modello spazio temporale.....	15
4.1	Specificazione delle distribuzioni a priori e implementazione del modello	16
4.2	Predizione e statistiche descrittive delle distribuzioni a posteriori	17
4.3	Implementazione	18
5	Risultati e discussione.....	19
5.1	Parametri del modello	19
5.2	Validazione del modello	21
5.3	Mappe della variazione relativa delle concentrazioni di NO ₂ 2020 vs 2019	22
6	CONCLUSIONI.....	28
7	Bibliografia.....	31



1 INTRODUZIONE

Al fine di ridurre l'inquinamento atmosferico e i suoi effetti sulla salute umana negli ultimi 40 anni i paesi Europei hanno adottato diverse misure di risanamento della qualità dell'aria. Numerosi studi sono stati dedicati alla valutazione degli effetti delle misure implementate; in particolare alcuni studi hanno rivolto l'attenzione agli effetti nelle aree urbane dell'introduzione di zone a bassa emissione (low emission zone) e all'adozione di sistemi di tassazione legati al permesso di circolare in determinate aree (congestion charge), misure adottate per tentare di ridurre localmente il contributo dovuto al traffico veicolare (e.g. Fassò et al., 2013; Holman et al., 2015; Maranzano et al. 2020); altri hanno valutato l'effetto dell'applicazione di limiti più restrittivi al contenuto di zolfo nei combustibili utilizzati dalle imbarcazioni (e.g. Grange & Carslaw, 2019); diversi studi hanno valutato anche un set più ampio e articolato di misure (per una review si veda ad esempio Burns et al., 2020; per un caso su ampia scala si veda ad esempio Font & Fuller 2016).

In generale si può affermare che per coloro che si occupano di valutazione e gestione della qualità dell'aria un aspetto cruciale è proprio la valutazione dell'efficacia di uno o più specifici interventi o politiche di risanamento della qualità dell'aria.

In particolare valutare quantitativamente la variazione nella concentrazione di un inquinante attribuibile agli interventi di risanamento adottati può essere difficile a causa della complessità delle dinamiche dell'evoluzione nel tempo e nello spazio dell'inquinamento atmosferico, fortemente influenzate dalle condizioni meteorologiche. Inoltre è molto spesso di precipuo interesse valutare quantitativamente la variabilità spazio temporale dell'eventuale effetto.

Le misure di contenimento (lockdown) prese nel 2020 per ridurre la diffusione del virus SARS-CoV-2 hanno determinato un'improvvisa riduzione di parte delle attività umane e, con essa, delle emissioni dei principali inquinanti atmosferici; è stato dunque possibile studiare l'effetto che potrebbero avere politiche di risanamento della qualità dell'aria che prevedano una sostanziale riduzione delle emissioni, in particolare quelle determinate dal traffico veicolare. Da questo punto di vista è subito emersa la necessità di valutare tali effetti controllando per la meteorologia, la componente tendenziale di lungo termine ed altri possibili fattori di confondimento.

La letteratura su questo argomento in breve tempo è cresciuta in modo esponenziale come testimoniano due recenti review (Gkatzelis et al., 2021; Rana et al., 2021).



Diversi studi hanno evidenziato fin dai primi giorni di applicazione delle restrizioni l'effetto positivo sui livelli di NO₂, attribuibile in larga parte alla repentina riduzione del traffico veicolare; tale riduzione dei livelli di NO₂ appariva comunque non omogenea nei vari domini di studio. Ad esempio diversi lavori hanno utilizzato le osservazioni dallo spazio del satellite Sentinel 5-P per stimare una riduzione variabile tra il 20 e il 55% tra gennaio ed aprile 2020 rispetto allo stesso periodo del 2019 in molte città in Cina, India, Pakistan, Europa occidentale e Stati Uniti (Ali et al., 2021a; Ali et al., 2021b; Bar et al., 2021; Dutta et al., 2021; Muhammad et al., 2020).

Per quanto riguarda l'Italia è stata osservata (Bauwens et al., 2020), mediante le osservazioni del satellite TROPOMI una riduzione del contenuto colonnare di NO₂ del 38% ($\pm 10\%$) durante il lockdown del 2020 rispetto allo stesso periodo del 2019. Analoghi risultati, ottenuti utilizzando sia dati in situ che dati satellitari, sono stati riportati da Cerosimo et al., (2020) sull'ampio territorio del bacino padano. Una riduzione media del 50% rispetto al 2019 è stata documentata, basandosi sui dati della rete di monitoraggio locale (Kumari et al., 2020; Bassani et al., 2021).

Analoghi studi hanno focalizzato l'attenzione su alcune città della Toscana (Donzelli et al., 2021), su Napoli (Sannino et al., 2021) e Reggio Emilia (Marinello et al., 2021).

La principale debolezza degli studi osservazionali sopra citati risiede nel fatto che essi si basano essenzialmente sul confronto tra i dati misurati durante il lockdown e quelli misurati nel periodo immediatamente precedente o su quelli misurati nello stesso periodo di anni precedenti; in sostanza manca la valutazione dell'effetto della meteorologia che in periodi diversi può essere favorevole o sfavorevole alla dispersione degli inquinanti determinando quindi una sottostima o una sovrastima degli effetti del lockdown. Tanto per fare un esempio il primo quarto dell'anno 2020 ha fatto registrare significative anomalie positive di temperatura sul nostro continente che potrebbero aver influenzato i valori osservati, rappresentando quindi un fattore di confondimento per gli studi osservazionali (Barrè et al., 2020; Van Heerwaarden et al., 2021).

Diversi studi hanno affrontato il problema di valutare gli effetti del lockdown sulla qualità dell'aria usando modelli chimici di trasporto. In questo caso le simulazioni ottenute con un input emissivo Business As Usual (BAU) sono state confrontate con i valori osservati in situ oppure con le simulazioni ottenute elaborando un input emissivo specifico per la situazione di lockdown (e.g. Barrè et al., 2020; Menut et al., 2020; Piccoli et al., 2020; Putaud et al., 2020; Zhe et al., 2021).



Nell'ambito del progetto Pulvirus tale approccio è stato applicato al caso italiano e i relativi risultati sono riportati nei report dell'obiettivo 2 cui si rimanda (<https://www.pulvirus.it/index.php/obiettivi/obiettivo-2/>).

Altri studi hanno affrontato il problema utilizzando algoritmi di machine learning o modelli statistici al fine di valutare a partire dai dati osservati in situ, l'effetto del lockdown, dopo aggiustamento per i vari confondenti, in primis la meteorologia.

I dati storici degli anni precedenti o del periodo pre-lockdown sono stati usati per addestrare algoritmi di machine learning (e.g. Barrè et al., 2020; Diémoz et al., 2021; Granella et al., 2021; Grange et al., 2021; Keller et al., 2021; Kim et al., 2021; Petetin et al., 2020) o per stimare modelli statistici, come modelli di regressione multipla (Bao et al., 2020; Dacre et al., 2020; Hoermann et al., 2021) modelli additivi generalizzati (Carlos et al., 2020; EEA, 2020; Solberg et al., 2021a; Solberg et al., 2021b), modelli ARIMA – *Autoregressive Integrated Moving Average models* (Tyagi et al., 2020). I modelli sviluppati sono poi stati utilizzati per predire le concentrazioni del 2020 nello scenario BAU, ovvero assumendo che il lockdown non avesse avuto luogo. Al fine di aggiustare per gli effetti della meteorologia e per gli effetti della tendenza di fondo, nei modelli sono stati incluse varie variabili meteorologiche e temporali sia come effetti lineari che come effetti non lineari. Le differenze tra le stime ottenute dai modelli e le concentrazioni osservate (i.e. gli errori di predizione) sono stati utilizzati come stima degli effetti del lockdown.

Un altro approccio è stato quello di utilizzare come controfattuale i dati di concentrazione rilevati in città non soggette ai provvedimenti restrittivi (e.g. He et al., 2020; Wang et al., 2021). Questi modelli, detti DID (Difference-In-Differences) sono stati usati per confrontare la variazione relativa nelle concentrazioni di vari inquinanti in un gruppo di città (dove il lockdown è stato implementato) con un gruppo di controllo (città dove il lockdown non è stato implementato).

Un'altra strategia usata è stata quella di applicare modelli di serie temporali dove la variabile risposta è la concentrazione di un inquinante misurato nel 2020 e in alcuni casi anche negli anni precedenti. L'effetto del lockdown è incluso nel set di regressori come una variabile dummy dipendente dal tempo, insieme agli altri regressori (variabili meteorologiche e temporali). In questo caso l'effetto del lockdown è stato valutato sulla base del valore che assume di volta in volta il coefficiente della variabile "lockdown" e della sua interazione con le altre variabili.



Indipendentemente dalla strategia modellistica scelta le serie di dati possono essere analizzate separatamente o congiuntamente. Questa seconda soluzione permette una stima dei parametri iù efficace e una maggiore performance predittiva, considerato il largo volume di dati disponibile.

Inoltre rileva il fatto che poiché i punti di misura sono distribuiti nello spazio risulta conveniente tener conto non solo della correlazione temporale ma anche della correlazione spaziale al fine di spiegare fino in fondo la variabilità dei residui.

Questo tipo di approccio è in particolare un'opzione consolidata che scaturisce dall'osservazione che ci aspettiamo la presenza di correlazione temporale tra punti di misura vicini (Finazzi et al., 2013; Lee et al., 2016; Sahu et al., 2006). Finora l'unico lavoro che ha considerato la presenza di correlazione spaziale tra le osservazioni, implementando un modello spazio-temporale per valutare gli effetti del lockdown sulla qualità dell'aria è stato quello di Beloconi et al., 2021. Tuttavia la valutazione dell'impatto del lockdown è limitata ai soli punti dove sono collocate le stazioni di monitoraggio e non sono fornite stime spaziali e temporali sull'intero dominio di studio.



2 OBIETTIVI

L'obiettivo dell'attività 1.4.3. è stato quello di sviluppare un framework metodologico per stimare in modo continuo nello spazio e nel tempo l'effetto del lockdown sulla qualità dell'aria.

L'obiettivo di ricerca è fondato sull'ipotesi che la disponibilità di mappe 2D di concentrazione ad alta risoluzione spaziale possa aiutare a valutare se l'effetto del lockdown sia stato omogeneo in una data area (ovvero a comprendere quale sia stato il grado di disomogeneità).

L'esercizio è stato condotto sull'inquinante biossido di azoto in quanto è stato chiaramente tra gli inquinanti per i quali le misure introdotte hanno determinato una significativa riduzione delle emissioni e per il quale quindi è attesa una significativa variazione attribuibile al lockdown.

La variabile target prescelta è stata la differenza di concentrazione osservata giorno per giorno tra il 2020 e il 2019 nei mesi di marzo e di aprile. Questo permette di stimare le differenze di concentrazione tenendo conto della meteorologia e di altri fattori confondenti.

In particolare, includendo una componente spaziale stocastica il modello sviluppato permette di tener conto della correlazione spaziale tra le osservazioni; le superfici di predizione così generate appaiono continue spazialmente e permettono di valutare l'effetto del lockdown anche nelle aree remote o montuose dove non sono disponibili dati puntuali per la mancanza di stazioni di monitoraggio (Diémoz et al., 2021).

L'approccio modellistico usato può essere facilmente generalizzato allo studio di casi diversi da quello oggetto del progetto Pulvirus, ovvero qualora si sia interessati a valutare gli effetti su larga scala di misure di risanamento della qualità dell'aria.

3 METODI

3.1 Siti di monitoraggio e dati di qualità dell'aria

I dati di concentrazione di NO₂, misurati nel 2019 e nel 2020 nelle stazioni di monitoraggio distribuite sul territorio nazionale, sono raccolti e archiviati in ISPRA nel database InfoARIA. I dati sono trasmessi dalle Regioni e Province Autonome secondo quanto previsto dalla Decisione 2011/850/EU. Ai fini del progetto sono stati raccolti ed elaborati con i criteri riportati nel report delle attività 1.3 (www.pulvirus.it).

Abbiamo qui utilizzato le medie giornaliere di NO₂ nel periodo 1 marzo 2020 – 30 aprile 2020, corrispondente a 10 settimane di osservazione.

Il dataset comprende dati relativi a 200 stazioni di monitoraggio distribuite sull'intero territorio nazionale con un basso tasso di dati non validi (< 25% per stazione) distribuiti su 8 regioni e province autonome d'Italia (Valle d'Aosta – 4 stazioni, Piemonte – 17; Veneto – 32; Lombardia – 55; Provincia autonoma di Trento – 5; Friuli Venezia giulia – 12; Provincia autonoma di Bolzano – 5; Emilia Romagna – 36; Toscana – 34). La distribuzione spaziale delle stazioni selezionate come si può osservare in figura 1. Le stazioni sono collocate in aree urbane (123) suburbane (39) e rurali (38).

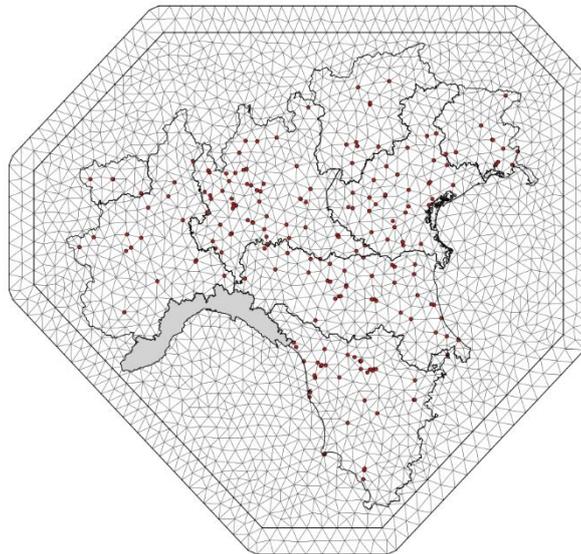


Figura 1. Distribuzione spaziale dei siti di monitoraggio del biossido di azoto (NO₂), e mesh adottata per l'implementazione del modello spazio-temporale.

In tabella 1 sono riportate le statistiche descrittive delle concentrazioni di NO₂ per il periodo di osservazione da cui si evince immediatamente la significativa riduzione media nel 2020 rispetto al



2019.

Area		2019					2020				
		Media	DS	Min	Mediana	Max	Media	DS	Min	Mediana	Max
Marzo	Bolzano	34.7	11.5	11	33	72	24.2	11.6	4	22	55
	Trento	30.7	17.8	3	30	92	19.6	12.5	3	18	61
	Emilia Romagna	24.8	16.0	<1	22	85	16.3	10.6	<1	14	57
	Friuli Venezia Giulia	21.1	9.9	3	20	53	14.2	9.1	<1	13	42
	Lombardia	32.1	15.5	2	30	99	22	11.6	2	20	85
	Piemonte	27.5	16.3	3	24	92	17.8	9.1	3	16	45
	Toscana	21.6	13.9	<1	20	80	15.5	10.7	<1	14	62
	Valle d'Aosta	13.0	8.5	1	11.5	33	11.1	9.1	1	10	50
	Veneto	27.1	12.6	3	27	68	17.8	10.1	2	16	49
Aprile	Bolzano	26.2	9.2	7	25	50	16.8	4.8	6	17	29
	Trento	22.7	13.7	3	21.5	58	13.5	6.2	4	13	33
	Emilia Romagna	19.3	13.2	<1	16	72	10.9	6.6	<1	9	40
	Friuli Venezia Giulia	14.2	7.8	1	13	37	9.7	4	1	9	25
	Lombardia	23.0	13.6	1	20	97	15.6	7.8	1	14	58
	Piemonte	19.8	10.0	3	18	73	11.9	6.1	1	11	31
	Toscana	19.7	13.3	<1	17	83	10.1	6.2	1	9	33
	Valle d'Aosta	12.0	7.9	<1	11	32	6.8	3.5	1	6	14
	Veneto	18.3	11.2	2	16	62	11.6	6.3	2	10	35

Tabella 1. Statistiche descrittive – media, deviazione standard (DS), minimo (Min), mediana e massimo (Max) – per le concentrazioni di NO₂ (µg/m³) per le regioni e province autonome considerate e per i mesi di marzo e aprile 2019 e 2020.

3.2 Differenze giornaliere

Per calcolare le differenze giorno per giorno tra i due anni abbiamo tenuto conto del fatto che le concentrazioni nei giorni feriali differiscono mediamente in modo significativo da quelle dei giorni festivi e prefestivi. Pertanto piuttosto che calcolare la differenza tra il giorno i^{mo} del 2019 e il giorno i^{mo} del 2020 abbiamo preliminarmente individuato settimane omologhe: ad esempio la prima settimana di marzo 2019 (4-10 marzo 2019) è omologa alla prima settimana del 2020 (2-8 marzo 2020). Quindi abbiamo calcolato la differenza tra giorni della settimana (lunedì con lunedì ecc.) della stessa settimana omologa individuata dal suo numero identificativo secondo lo standard ISO-8601. Con tale approccio quindi i giorni feriali sono stati confrontati con giorni feriali e i giorni festivi con i giorni festivi. Nel computo però non sono state prese in considerazione le festività cadute in un anno e non nell'altro. Ad esempio il Lunedì dell'Angelo il 25 aprile 2020 corrispondono a giorni feriali nel 2019.

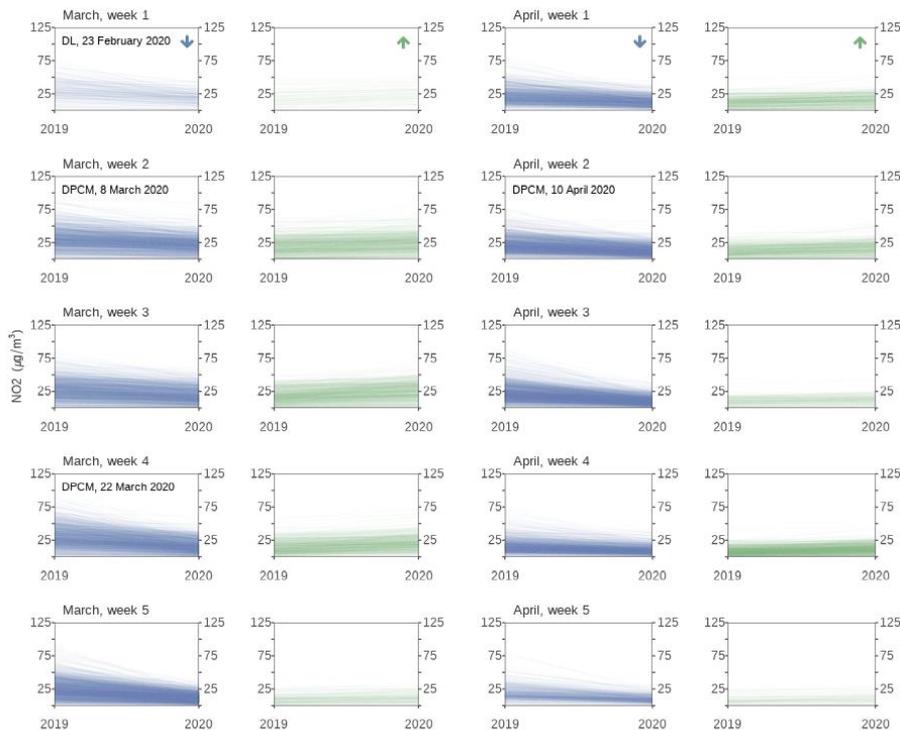


Figura 2. Concentrazioni giornaliere di NO₂ allineate 2019-2020 durante le settimane di marzo e aprile. Ogni riga rappresenta una coppia di dati allineati di un sito di monitoraggio, distinguendo tra decrementi (linee blu) e incrementi (linee verdi) dei livelli di NO₂. Nei riquadri sono riportati come testo i diversi decreti governativi e le norme del lockdown italiano (DPCM: Decreto del Presidente del Consiglio dei Ministri; DL: Decreto legge). Ogni grafico settimanale rappresenta 1400 linee (200 siti di monitoraggio per 7 giorni). Si noti che dopo il processo di allineamento la prima settimana di marzo contiene un solo giorno (domenica, 200 righe) e l'ultima settimana di aprile solo due giorni (lunedì e giovedì, 400 linee).

In figura 2 sono riportati i “parallel plot” con i dati giornalieri aggregati su base settimanale. Si osserva



molto bene la riduzione delle concentrazioni nel 2020 rispetto al 2019 in particolar modo nelle ultime due settimane di marzo.

Allo stesso modo si evidenziano in alcune stazioni e per alcune settimane situazioni in cui le concentrazioni nel 2020 sono risultate maggiori rispetto al 2019, evidenziando il fatto che il fenomeno, anche per il biossido di azoto, non è stato omogeneo nello spazio e nel tempo.

Una piccola frazione de dati allineati su base giornaliera (3,5%) presentavano variazioni percentuali maggiori del 100% - ampiamente al di fuori del trend generale dell'intero dataset e ai fini dell'analisi condotta sono stati rimossi.

3.3 Regressori spaziali e temporali

Per ogni sito di monitoraggio, abbiamo selezionato 13 variabili esplicative indipendenti (vedi tabella 2). I regressori temporali, con risoluzione giornaliera, sono costituiti da variabili descrittive delle condizioni meteorologiche. 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).

Per descrivere parte della variazione spaziale delle differenze giornaliere di NO₂, sono state utilizzate tre variabili geografiche (costanti nel tempo): la distanza lineare dalla strada principale più vicina, l'altitudine e la percentuale di terreni agricoli e seminativi.

Yegane et al. (2018) hanno rilevato che i dati sul volume del traffico e sulla congestione per tutte le singole strade possono migliorare efficacemente la modellazione spazio-temporale delle concentrazioni di NO₂. Sfortunatamente, queste informazioni non sono disponibili per l'intero indagato dominio.

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, su tutto il globo terrestre. Il modo in cui il tempo influisce sulle concentrazioni di NO₂ viene valutato utilizzando 10 variabili (come precipitazioni totali, velocità del vento, relativa umidità, pressione superficiale) recuperati dal set di dati ERA5-Land dal Copernicus Climate Data Store (<https://climate.copernico.eu/>). Per la sola *hpbl* sono stati usati i 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 $0.25^\circ \times 0.25^\circ$.

Variabile	Descrizione	Unità di misura	Metodo di misurazione
<i>t2m</i>	temperatura media dell'aria a 2 metri d'altezza sulla superficie terrestre	°C	Media giornaliera dei valori di <i>temp</i>
	Range di temperatura diurno	°C	Differenza tra massimo e minimo giornaliero
<i>rh</i>	umidità relativa percentuale dell'aria sulla superficie terrestre	%	Media giornaliera ottenuta da elaborazione dei valori orari di <i>temp</i> e <i>dewP</i>
<i>tp</i>	precipitazione cumulata sulla superficie terrestre	mm	Cumulato giornaliero al giorno <i>g</i> ottenuto da elaborazione dei valori di <i>prec</i>
<i>wspeed</i>	Intensità della velocità orizzontale del vento a 10 metri d'altezza sulla superficie terrestre	m/s	Media giornaliera al giorno <i>g</i> ottenuta da elaborazione dei valori orari di <i>winU</i> e <i>winV</i>
<i>pwspeed</i>	Intensità della velocità orizzontale del vento a 10 metri d'altezza sulla superficie terrestre	m/s	Media giornaliera al giorno precedente (<i>g-1</i>) ottenuta da elaborazione dei valori orari di <i>winU</i> e <i>winV</i>
<i>sp</i>	pressione dell'aria sulla superficie terrestre	hPa	Media giornaliera dei valori di <i>pres</i>
<i>nirradiance</i>	irradianza solare netta che raggiunge un piano orizzontale sulla superficie terrestre	W/m ²	Cumulato giornaliero ottenuto da elaborazione dei valori di <i>Srad</i>
<i>pblmin</i>	altezza minima dello strato limite planetario	km	Minima giornaliera dei valori di <i>pblH</i>
<i>pblmax</i>	altezza massima dello strato limite planetario	km	Massima giornaliera dei valori di <i>pblH</i>
	Altitudine	m	
	Distanza lineare dalla strada principale più vicina	m	
	Terreni agricoli e coltivabili	%	

Tabella 2. Descrizione dei predittori spaziali (altitudine, distanza lineare dalla strada principale più vicina, terreni agricoli e seminativi) e spazio-temporali (ERA5) inclusi nel modello.

4 SVILUPPO DEL MODELLO SPAZIO TEMPORALE

Consideriamo una coppia di valori di concentrazione di NO₂: $y_{2019}^m(t, s_i)$ e $y_{2020}^m(t, s_i)$ temporalmente allineati secondo la procedura descritta nella sezione 3, dove s_i denota la stazione di monitoraggio i^{ma} , t ($t = 1, 2, \dots, T_m$) il giorno del mese m (marzo =1, aprile =2) degli anni 2019 e 2020 rispettivamente.

Definiamo come segue la differenza giornaliera delle concentrazioni di NO₂ log-traformate:

$$\Delta^m(t, s_i) = \log(y_{2020}^m(t, s_i)) - \log(y_{2019}^m(t, s_i)) = \log \frac{y_{2020}^m(t, s_i)}{y_{2019}^m(t, s_i)}$$

La trasformazione logaritmica è una scelta comune nelle analisi di dati di qualità dell'aria adottata al fine di ridurre la tipica asimmetria positiva osservata nelle distribuzioni dei dati (Ott, 1990).

Il lockdown è stato implementato nella fase finale della stagione invernale, quando le condizioni meteorologiche cominciano generalmente a tendere a favorire la dispersione degli inquinanti, mentre nel pieno della stagione invernale le condizioni che favoriscono l'accumulo degli inquinanti sono maggiormente frequenti; ci possiamo quindi aspettare una tendenza alla riduzione delle concentrazioni passando dai primi giorni di marzo alla fine di aprile. Per evitare il fattore di confondimento generato da questo aspetto, abbiamo preferito analizzare separatamente le differenze per i due mesi selezionati.

L'equazione generale che descrive le differenze può essere espressa come:

$$\Delta(t, s_i) = \mu(t, s_i) + \epsilon(t, s_i) \quad (2)$$

Dove $\epsilon(t, s_i) \sim N(0, \sigma_\epsilon^2)$ è l'errore di misura Gaussiano, che si assume indipendente nel tempo e nello spazio. Per semplicità nell'equazione 2 abbiamo ommesso l'indice m considerato che la struttura del modello è la stessa per i mesi considerati.

Il valore medio $\mu(t, s_i)$ è definito come la somma di effetti fissi e random come segue:

$$\mu(t, s_i) = \alpha_0 + \alpha_1 t + \gamma I_t^S + \mathbf{z}(s_i) \beta'_z + \mathbf{\Delta}_x(t, s_i) \beta'_x + v(s_i) + u(t, s_i) \quad (3)$$

Dove α_0 è l'intercetta e $\alpha_1 t$ è il trend temporale introdotto per tener conto della variazione intergiornaliera di breve termine nel mese dovuta all'avanzare della stagione. Il termine $\mathbf{z}(s_i)$ è il vettore p_z -dimensionale dei regressori spaziali, mentre $\mathbf{\Delta}_x(t, s_i)$ è il vettore p_x -dimensionale delle differenze dei regressori spazio-dimensionali calcolati a partire dalle variabili meteorologiche descritte nel paragrafo 3.3. Nel modello assumiamo effetti lineari per le covariate spaziali e spazio-



temporali mediante, rispettivamente, i vettori dei parametri β'_z e β'_x .

Al fine di valutare se durante il lockdown ci sia stato un effetto diverso tra giorni feriali e giorni festivi abbiamo aggiunto una variabile dummy I_t^S che assume il valore 1 quando t è domenica, e 0 negli altri casi. Il corrispondente coefficiente γ rappresenta la variazione attesa nella differenza media nei giorni di domenica.

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. 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:

$$u(t, s_i) = a u(t - 1, s_i) + \omega(t, s_i)$$

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

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 $C(h)$ la funzione di covarianza di Matérn con varianza σ_ω^2 range ρ e parametro di smoothness $\nu = 1$. Per maggiori dettagli teorici sulla struttura della covarianza qui applicata si veda per esempio Cameletti et al., 2011 e Cameletti et al., 2013.

4.1 Specificazione delle distribuzioni a priori e implementazione del modello

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 α_0 , α_1 , e per gli elementi di β'_x e β'_z sono state definite distribuzioni a priori non informative. Per i restanti parametri sono stati 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 (σ_ε e σ_ν) 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 σ_ε e per σ_ν . Questa scelta è stata motivata dal fatto che abbiamo verificato che la deviazione standard totale delle differenze delle concentrazioni di NO_2 log-trasformate è pari a circa 0,5 in ogni mese, pertanto è molto probabile che la varianza di ogni componente sia effettivamente



inferiore a 1.

Per quanto riguarda ρ e σ_ω è stata utilizzata la distribuzione a priori suggerita da Fulgstad et al., 2019, specificata come segue:

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

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 α_a .

L'inferenza è stata condotta utilizzando l'approccio INLA-SPDE (Lindgren & Rue, 2015; Martino & Riebler, 2020) che risulta computazionalmente più veloce dei metodi Monte Carlo basati sulla catena di Markov, comunemente usati per l'inferenza Bayesiana.

4.2 Predizione e statistiche descrittive delle distribuzioni a posteriori

Una volta implementato il modello utilizzando i dati osservati, abbiamo usato il metodo di simulazione di Monte Carlo (MC) per generare un largo numero di campioni (1000) dalla distribuzione delle predizioni a posteriori di $\Delta(t, s)$ per ciascun punto di misura s nel dominio di studio e per ciascun giorno t :

$$p(\Delta(t, s)|D) = \int p(\Delta(t, s)|\theta)p(\theta|D) \dots\dots\dots(4)$$

Dove $\theta = \alpha_0, \alpha_1, \gamma, \beta_x, \beta_z, a, \rho, u(t, s), \sigma_\varepsilon^2, \sigma_v^2, \sigma_\omega^2$ è il vettore di tutti i parametri del modello, la cui incertezza è mediata su tutti i dati D . Per semplicità il generico valore campionato è stato denotato come $\hat{\Delta}(t, s)$.

Per generare le mappe abbiamo usato una griglia con risoluzione spaziale di 1km x 1km. Per ogni unità della griglia, in cui cade uno dei punti di misura s , abbiamo simulato 1000 valori $\hat{\Delta}(t, s)$ dall'equazione 4. Nel calcolare le predizioni abbiamo posto uguale a zero il vettore $\Delta_x(t, s)$. **Questo corrisponde ad assumere che le condizioni meteorologiche siano identiche nel 2019 e nel 2020 per ogni locazione e unità temporale.**

Quindi abbiamo derivato la distribuzione a posteriori della variazione relativa dei livelli di NO₂ tra il 2020 e il 2019 usando la seguente trasformazione:

$$\tilde{\Delta}(t, s) = \exp(\tilde{\Delta}(t, s) - 1) = \frac{\hat{y}_{2020}(t, s)}{\hat{y}_{2019}(t, s)} - 1 \quad (5)$$

Dove $\tilde{\Delta}(t, s)$ assume valori negativi (positivi) se le concentrazioni di NO₂ sono minori (maggiori) nel



2020 rispetto al 2019, e uguali a zero nel caso di nessuna variazione.

Infine abbiamo mediato le mille simulazioni di montecarlo (MC) per la distribuzione giornaliera di $\tilde{\Delta}(t,s)$ alla risoluzione temporale settimanale. Il risultato è una collezione di 1000 predizioni rappresentate sulla griglia di 1 km x 1km e visualizzabili come mappe. Da queste abbiamo estratto i valori dei quantili 2.5 e 97.5 delle medie a posteriori. Questi identificano la massa delle distribuzioni a posteriori delle concentrazioni di NO₂ per ogni cella della griglia e sono stati usati per determinare l'intervallo credibile della distribuzione al 95%. Qualora tale intervallo credibile non include lo zero, la corrispondente variazione relativa risulta diversa da zero a un livello di significatività del 95%. Infine vale la pena osservare che per tener conto del ciclo settimanale delle concentrazioni di NO₂ atteso per la relazione tra le concentrazioni di questo inquinante e le emissioni dovute al traffico veicolare, abbiamo generato le mappe per la media delle differenze e per i quantili distinguendo tra giorni lavorativi e pre-festivi (lunedì-sabato) e giorni festivi (Domenica).

4.3 Implementazione

Per implementare il modello è stato usato il software R 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>) e il software CDO (<https://code.mpimet.mpg.de/projects/cdo>).



5 RISULTATI E DISCUSSIONE

5.1 Parametri del modello

La figura 3 mostra le distribuzioni a posteriori per i coefficienti degli effetti fissi (α_0 , α_1 , γ , β_x , β_z). In generale possiamo osservare che un effetto significativo invariance in segno per i mesi di marzo e aprile caratterizza la maggior parte dei regressori selezionati. La forma delle distribuzioni a posteriori è confrontabile nei modelli per i due mesi, anche se si possono apprezzare alcune eccezioni. Nel caso della distribuzione del coefficiente α_1 rappresentativa del trend lineare osserviamo minore dispersione nel mese di marzo che nel mese di aprile; l'osservazione opposta emerge se consideriamo la distribuzione del coefficiente α_0 rappresentativa dell'intercetta.

Questo sembra coerente con l'ampia variabilità che caratterizza le previsioni settimanali del mese di aprile (vedi sezione 5.3). Per quanto riguarda la Pressione superficiale le distribuzioni a posteriori appaiono particolarmente disperse (forma allargata della curva), risultato di non facile interpretazione. Il coefficiente α_1 indicativo di un trend lineare assume valori negativi statisticamente significativi nel mese di marzo, coerente con il fatto che ci si aspetta una riduzione nel valore delle differenze giornaliere delle concentrazioni di NO₂ log-trasformate, proprio in coincidenza con il periodo in cui il lockdown è iniziato. Interessante osservare la significatività del coefficiente γ (con valore negativo) rappresentativo dell'effetto "Domenica". Possiamo considerare quindi che il ciclo settimanale persista anche quando si considerano le differenze giornaliere delle concentrazioni di NO₂ log-trasformate tra un anno e l'altro. Tuttavia in modo sorprendente né il coefficiente del trend lineare né quello della variabile dummy per l'effetto "Domenica" risultano significativi nel mese di aprile.

Per quello che riguarda i coefficienti delle variabili spazio-temporali meteorologiche possiamo distinguere tra quelli per i quali risulta un effetto significativo di segno positivo (il range di temperatura diurno, la temperatura media a 2 metri, l'umidità relativa e la pressione superficiale) e quelli con effetto statisticamente significativo di segno negativo (l'altezza del pbl minima e massima, l'irradianza netta, la velocità del vento, la precipitazione totale).

Tutti i coefficienti dei regressori spaziali (elevazione, percentuale di terreno agricolo/coltivabile, distanza dalle strade maggiori) hanno infine una distribuzione a posteriori di segno positivo. Questo potrebbe suggerire che allontanandoci dai centri abitati e dalle strade principali i livelli di NO₂ nel 2020 tendono ad essere simili a quelli del 2019 se non maggiori.

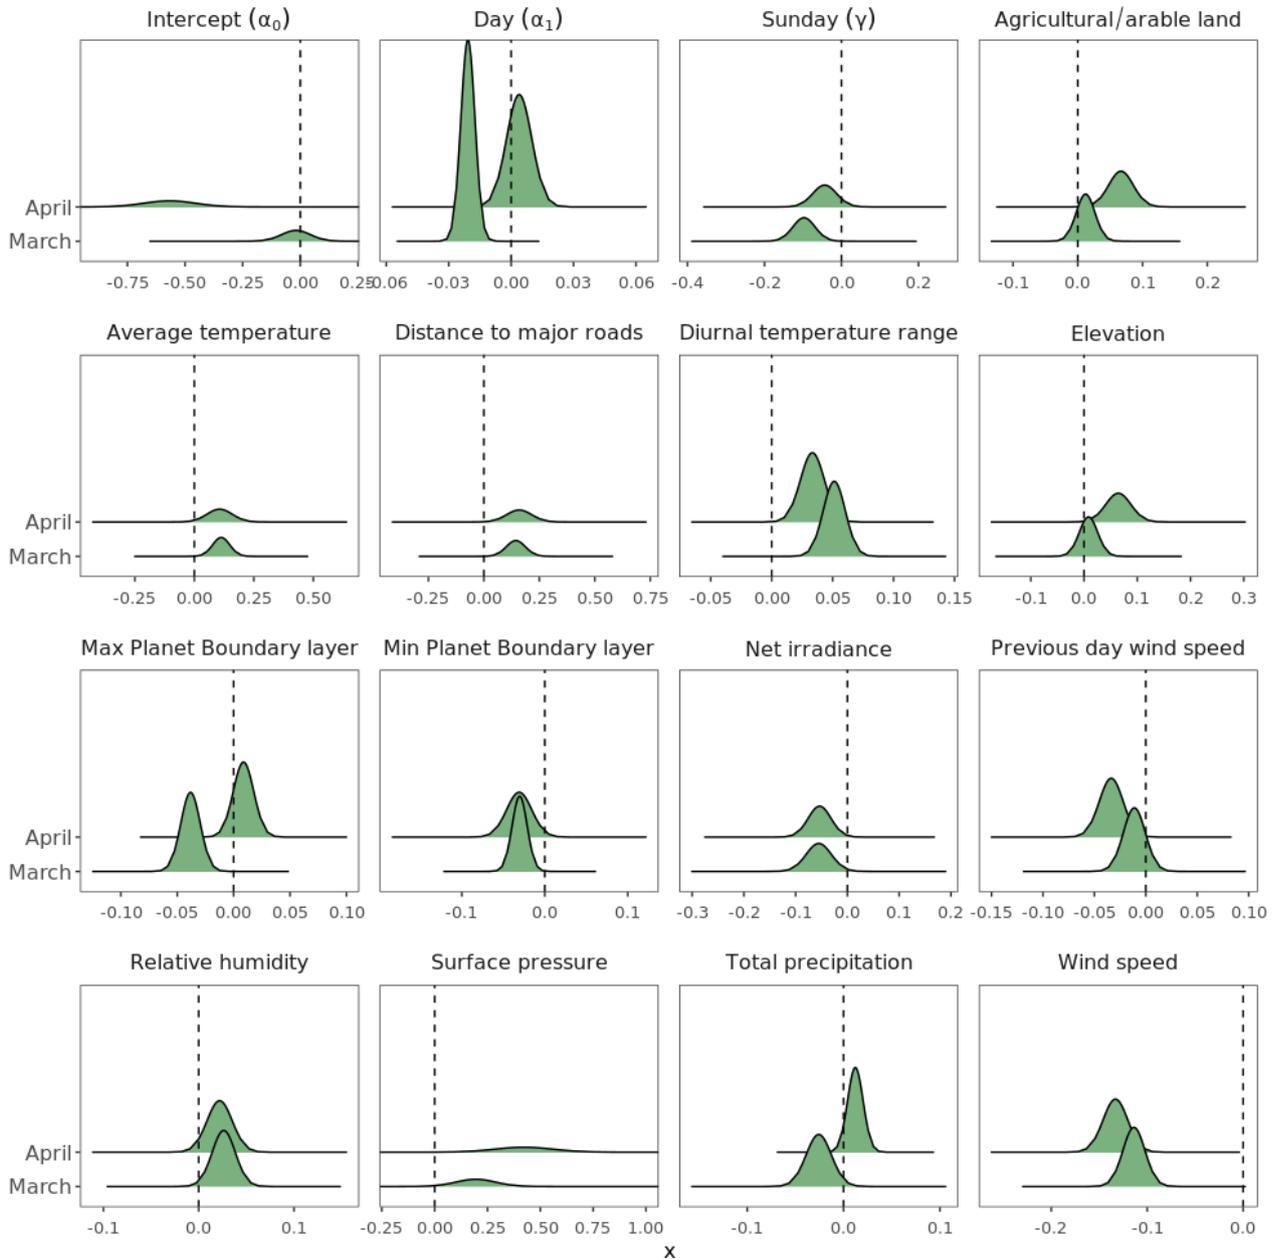


Figura 3 – distribuzioni a posteriori dei coefficienti del modello. Quando la maggior parte dell'area sottesa dalla curva cade lontano da zero (la linea tratteggiata nei grafici) si può concludere che il relativo coefficiente sia staticamente significativo.

In tabella 3 sono riportate le statistiche descrittive relative agli altri parametri del modello. Possiamo osservare che la media a posteriori del coefficiente di autocorrelazione AR(1) a , il range spaziale ρ e la deviazione standard σ_v risulta sempre maggiore in aprile che in marzo.

	a	ρ	σ_v	σ_ε	σ_ω
Marzo	0,64 (0,023)	74 (4,0)	0,16 (0,011)	0,21 (0,004)	0,37 (0,013)
Aprile	0,80 (0,021)	97 (5,5)	0,22 (0,015)	0,22 (0,003)	0,42 (0,021)

Tabella 3. Media a posteriori e deviazione standard (tra parentesi) dei parametri del modello per i mesi di marzo e aprile; a : coefficiente $AR(1)$; ρ e σ_ω range (in km) e deviazione standard della funzione di covarianza spaziale di Matérn; σ_v : deviazione standard degli effetti random su piccola scala spaziale; σ_ε : deviazione standard dell'errore di misura Gaussiano.

5.2 Validazione del modello

Ai fini della validazione, abbiamo stratificato i siti di monitoraggio degli input in base alla loro classificazione di tipo (urbano, suburbano e rurale stazioni). All'interno di ciascuno di questi gruppi, abbiamo campionato il 10% delle stazioni per definire un set di dati di validazione. Il resto delle stazioni (set di dati di training) sono state utilizzate per adattare il modello e il modello adattato è stato utilizzato per prevedere le differenze giornaliere delle concentrazioni di NO_2 log-trasformate (vedi equazione (1)) sul set di dati di convalida. Sia il campionamento che il processo di stima sono stati ripetuti tre volte per ogni mese. Il confronto dei valori previsti e osservati consente di indagare sulle prestazioni del modello nel predire valori nei punti dove non sono disponibili dati osservati, in particolare consente di valutare se il modello offre in tal senso prestazioni soddisfacenti sull'intero range di valori osservati o se soffre di *overfitting/underfitting*.

I grafici e le statistiche riassuntive sono mostrati come variazioni relative percentuali $\tilde{\Delta}(t, s) \%$ (vedi Equazione (5)) per facilità di interpretazione dei risultati della validazione. I grafici a dispersione nella Figura 4 mostrano la distribuzione dei valori predetti rispetto ai valori osservati.

I punti si estendono uniformemente lungo la linea diagonale, mostrando un buon accordo tra i dati osservati e modellati in entrambe le fasi di training e validazione. Come previsto, la variazione relativa stimata dal modello per la fase di convalida mostra una variabilità maggiore rispetto a quella stimata nella fase di training. Anche i coefficienti di correlazione di Pearson supportano le buone prestazioni del modello con un valore di 0,9 per la fase di addestramento e di $\sim 0,7$ per la fase di validazione. Infine, l'errore quadratico medio (RMSE) è risultato pari a $\sim 10\%$ e $\sim 20\%$ rispettivamente per la fase di training e per la fase di validazione.

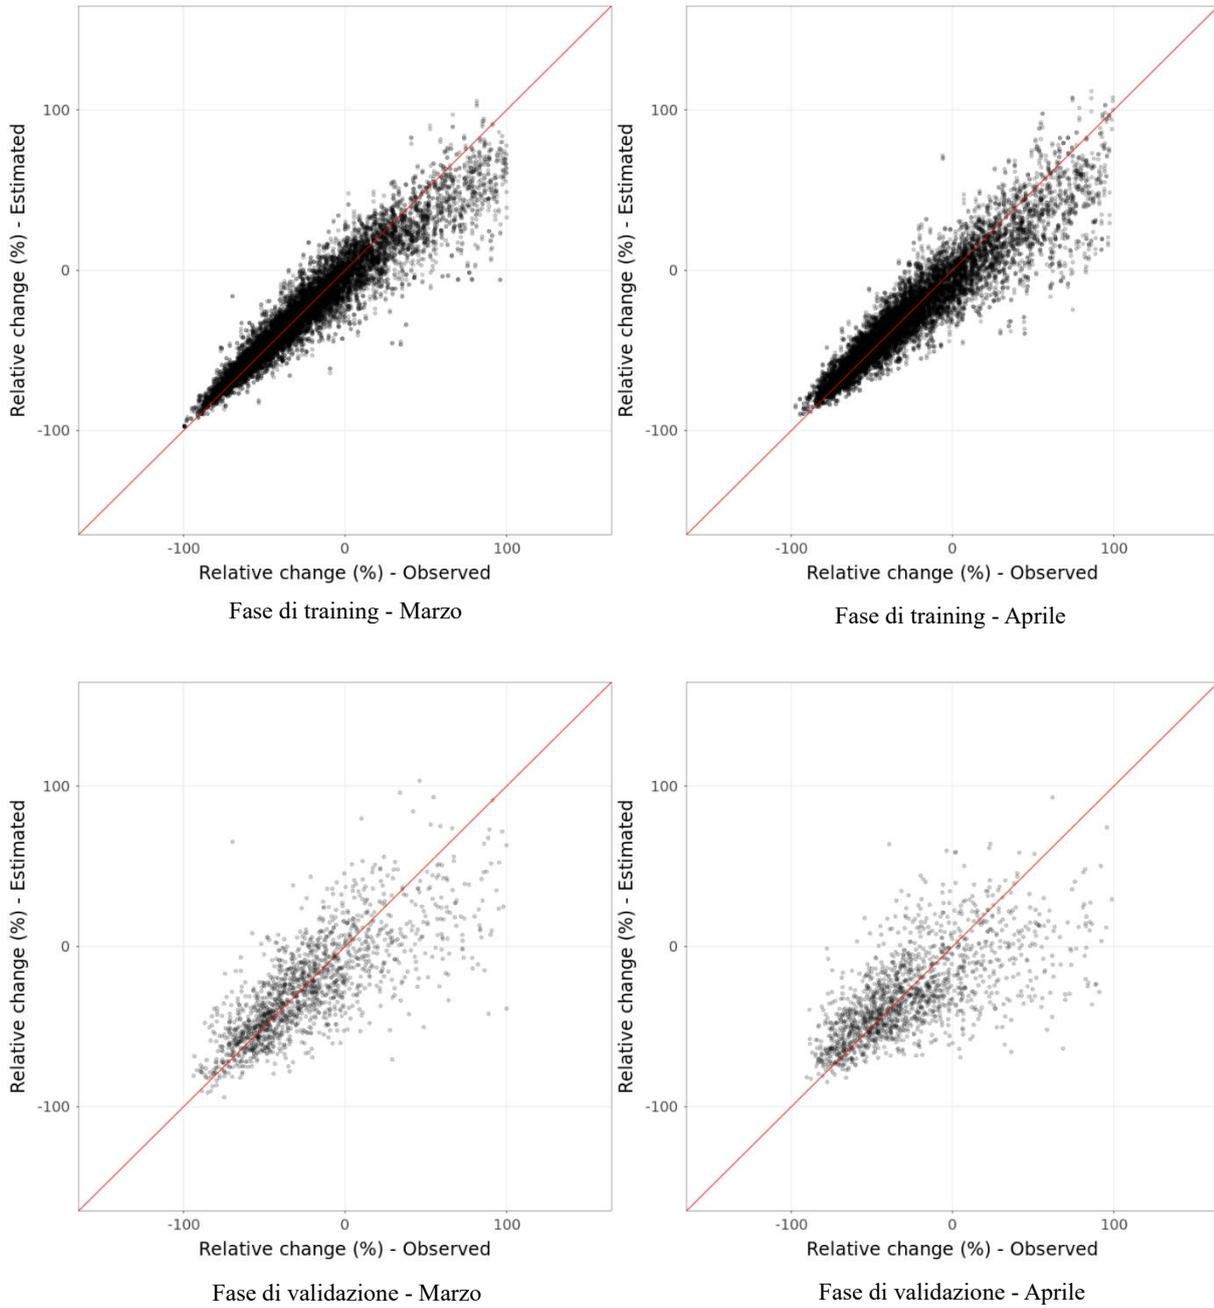


Figura 4. Accordo tra i valori stimati e i valori osservati delle variazioni relative delle concentrazioni di NO_2 ($\tilde{\Delta}(t, s)$ %) per la fase di addestramento (in alto) e per la fase di validazione (in basso). La linea rossa continua (1:1) è utilizzata come riferimento.

5.3 Mappe della variazione relativa delle concentrazioni di NO_2 2020 vs 2019

Utilizzando i predittori descritti nella Sezione 2.2 come singoli file raster, è stata implementata la procedura descritta nella Sezione 3.2 per ottenere mappe per ciascuna settimana dei mesi di marzo e Aprile che descrivono i pattern spaziali delle variazioni relative 2019/2020 nelle concentrazioni di



bioossido di azoto in Italia, durante il lockdown nazionale messo in atto per fronteggiare la pandemia di COVID-19. Le mappe sono riportate in figura 5 e 6 rispettivamente per i mesi di marzo e aprile. Si riferiscono sia alle stime medie settimanali ottenute dai giorni lavorativi (lunedì - sabato), sia alle stime settimanali della domenica. Questa distinzione tra le mappe dei giorni lavorativi e della domenica riflette la nostra scelta di includere un regressore fittizio per l'effetto domenica.

Vale la pena sottolineare che le mappe sono state ottenute a valle del processo di normalizzazione meteorologica descritto precedentemente (vedi Sezione 3.2). **Questo significa che sono state generate assumendo che, in ogni cella della griglia raster, le condizioni meteorologiche giornaliere siano state esattamente le stesse nel 2019 e nel 2020.** Matematicamente, questa ipotesi equivale a azzerare tutti i termini meteorologici nel nostro modello spazio-temporale. In questo modo le variazioni di concentrazione stimate nello spazio e nel tempo possono essere integralmente attribuite alla variazione delle emissioni tra i due anni, al netto della variabilità meteorologica esistente nei due anni.

Le figure rivelano una sostanziale diminuzione delle concentrazioni di NO₂ nei mesi di marzo e aprile 2020 rispetto al 2019. La riduzione è statisticamente significativa e persiste durante la terza e la quarta settimana lavorativa di marzo in tutta l'area di studio: l'intervallo interquartile della corrispondente distribuzione delle variazioni relative varia tra -40% e -20%, come mostrato nel boxplot nel pannello di sinistra della figura 5. In particolare, la terza e la quarta settimana di marzo corrispondono alla fase rigorosa del Confinamento per il covid19. Ad aprile abbiamo osservato una maggiore variabilità spaziale rispetto a marzo. Una diminuzione spazialmente omogenea, come quella osservata nella seconda metà di marzo, si verifica solo durante la terza settimana del mese (intervallo interquartile compreso tra -40% e -20%). In tutte le settimane il range interquartile risulta inferiore a zero con valori della mediana intorno al -30% denotando comunque una prevalenza di situazioni in cui le concentrazioni di NO₂ sono inferiori nel 2020 rispetto al 2019; tuttavia aumentano i valori outliers positivi (pannello di destra della Figura 7).

Mappe analoghe a quelle qui riportate ma estese a tutto il territorio nazionale sono state prodotte a partire dal modello qui descritto e validato; sono visualizzabili e navigabili mediante una dashboard interattiva disponibile sul sito del progetto: <https://www.pulvirus.it/index.php/obiettivi/obiettivo-1/task-4/>.

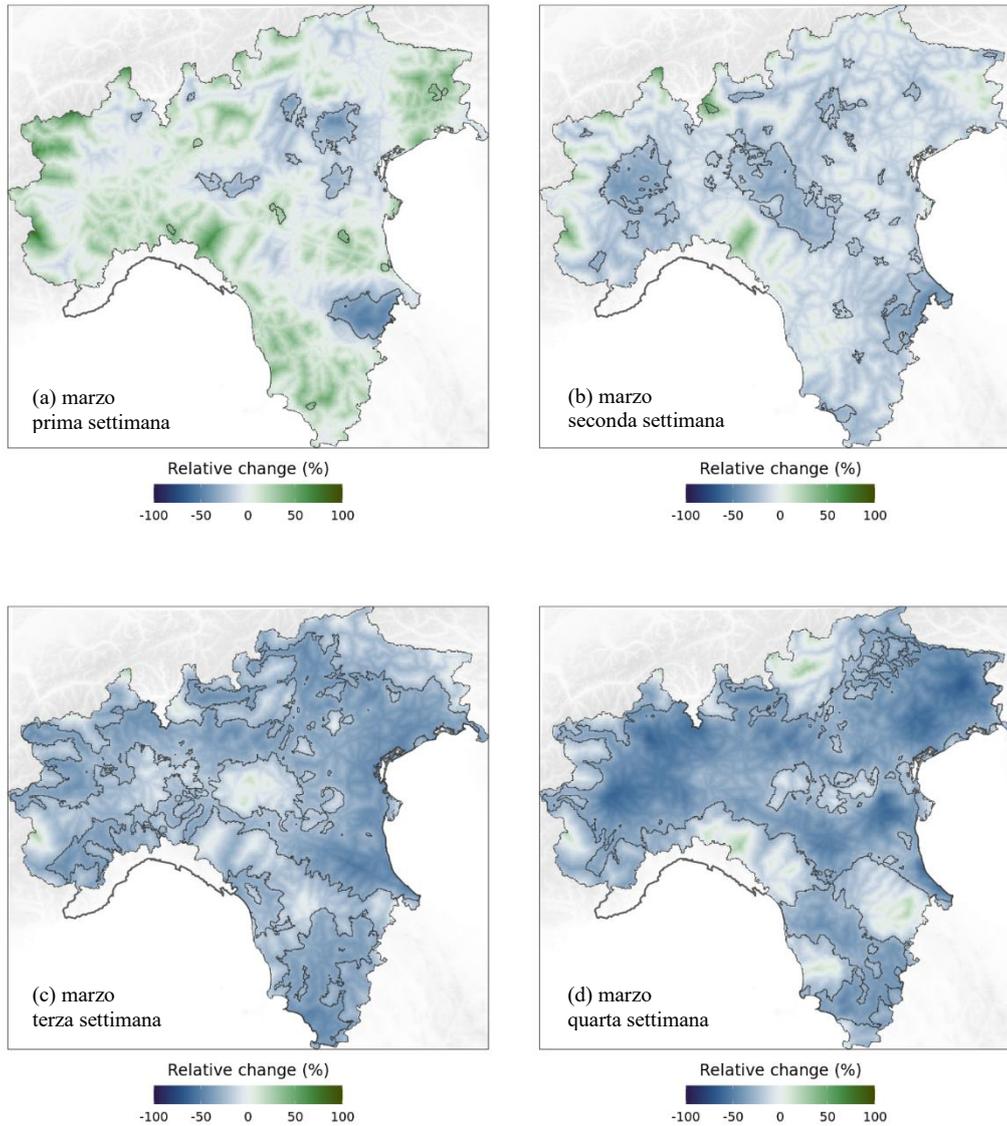


Figura 5 – Mappe delle variazioni percentuali medie settimanali 2020 vs 2019 delle concentrazioni di NO₂ per i giorni feriali (lunedì – sabato). Le linee di contorno evidenziano le aree dove la variazione stimata è statisticamente significativa al livello di significatività di 0,05.

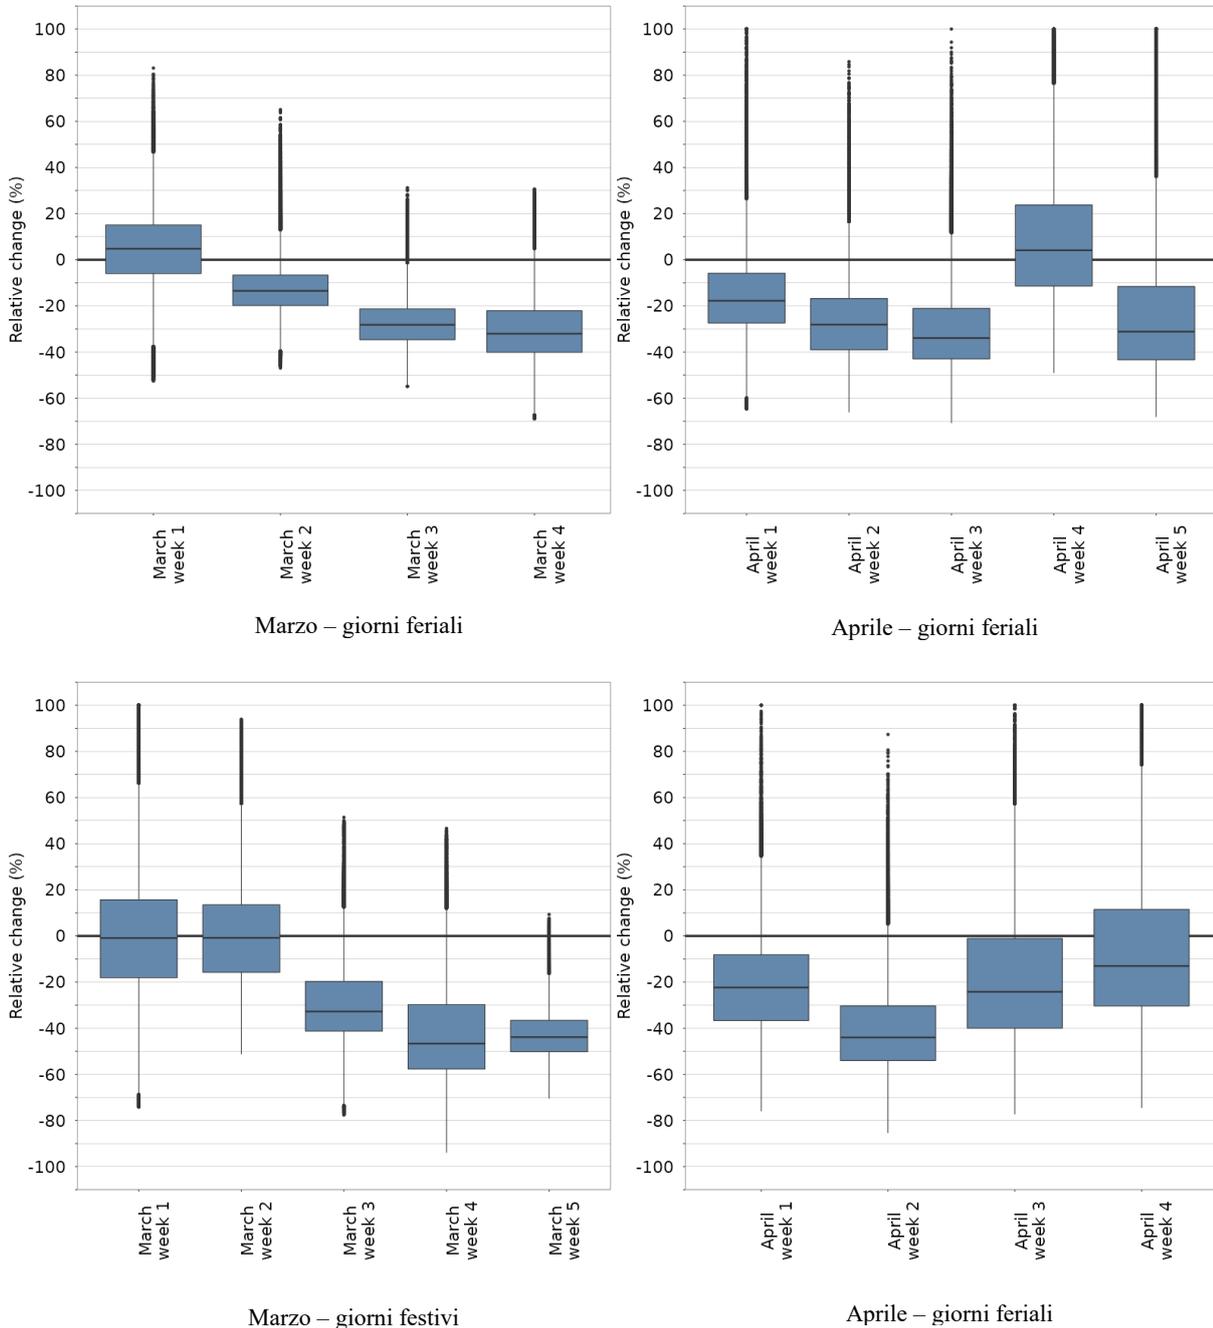


Figura 7. Box plot delle distribuzioni delle variazioni percentuali delle concentrazioni di NO₂ 2020 vs 2019 per i mesi di marzo (a sinistra) e di aprile (a destra) e per i giorni lavorativi (lunedì – sabato, in alto) e per le domeniche (in basso).

Come mostrato nella figura 8 variazioni statisticamente significative si sono avute principalmente nelle regioni Lombardia, Veneto, Friuli Venezia Giulia ed Emilia Romagna, mentre in Toscana, Valle d’Aosta e nelle province autonome di Trento e Bolzano le variazioni appaiono per lo più senza significatività statistica. Le aree urbane del bacino padano mostrano un consistente e statisticamente

significativa riduzione delle concentrazioni anche in tutto il mese di aprile, fatta eccezione per la quarta settimana.

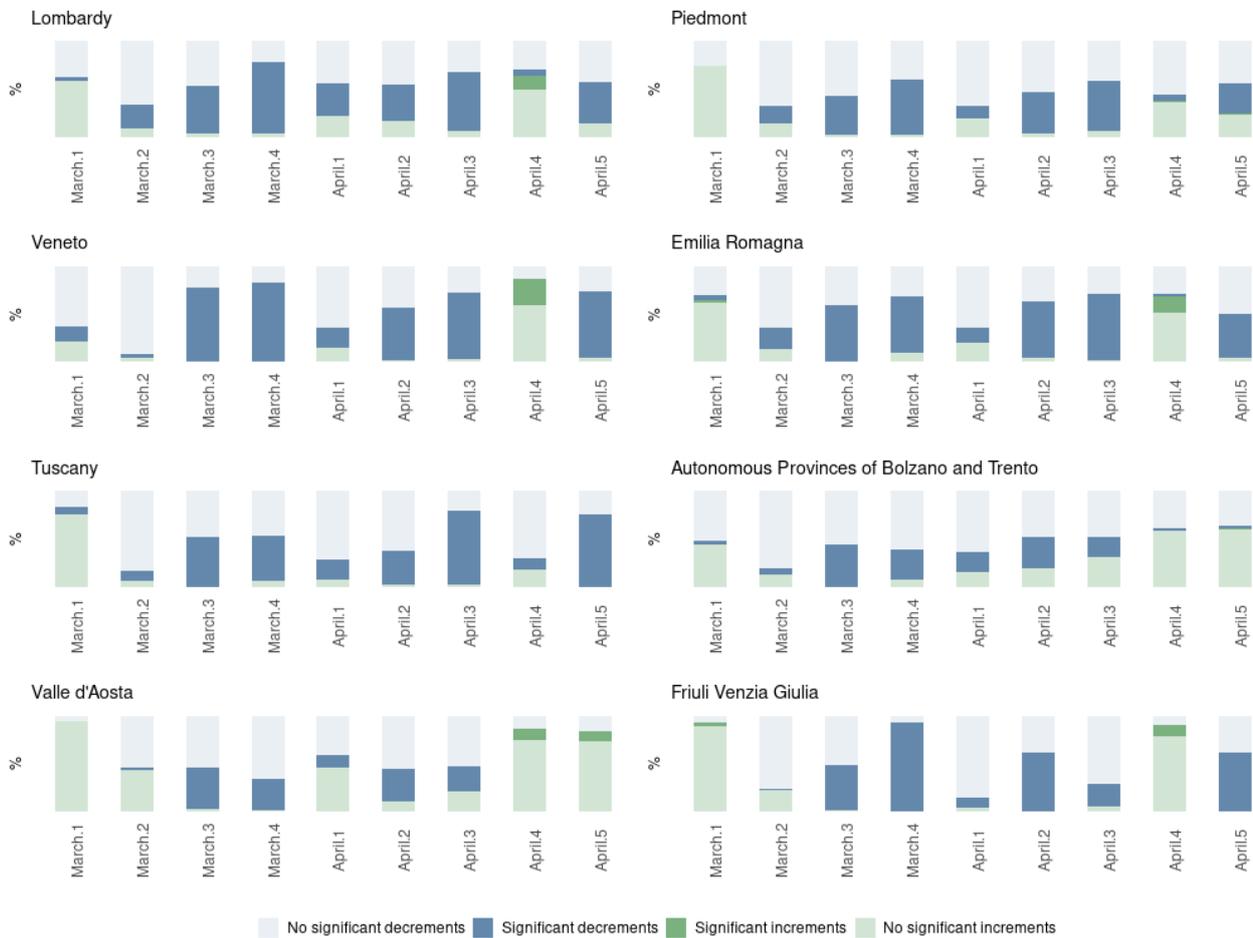


Figura 8 – Percentuale di celle nelle mappe dei valori predetti per i giorni lavorativi con variazioni percentuali positive (incrementi) o negativi (decrementi) e relativa significatività statistica.



6 CONCLUSIONI

In generale lo studio della variabilità spaziale e temporale della concentrazione degli inquinanti atmosferici è di fondamentale importanza per tutti coloro che sono coinvolti nelle attività di valutazione e gestione della qualità dell'aria. Una delle ragioni risiede nella rilevanza che assume la valutazione dell'efficacia di una o di un insieme di misure di risanamento sia in termini di entità ed omogeneità spaziale degli effetti che in termini della sua efficacia nel tempo. È ben noto che ogni valutazione di questo tipo, per poter essere di un qualche interesse deve adeguatamente prendere in considerazione il fattore di confondimento determinato dalla variabilità delle condizioni meteorologiche ex-ante ed ex-post.

Sebbene l'uso di modelli chimici di trasporto, che generino simulazioni ottenute con input emissivi rappresentativi dell'effetto della/delle misure di risanamento utilizzando lo stesso input meteorologico, rappresenti un'ottima soluzione per ottenere informazioni spazialmente e temporalmente risolte, occorre considerare che essi presentano alcuni svantaggi: l'accuratezza delle stime è fortemente dipendente dall'accuratezza dell'input emissivo e in alcuni casi le informazioni per generare tale input possono essere carenti o frammentarie. Inoltre non permettono di stimare l'incertezza delle predizioni che peraltro sono fortemente condizionate dalle condizioni iniziali e al contorno.

In questo senso i modelli statistici possono rappresentare una valida soluzione a complemento o integrazione delle simulazioni deterministiche; essi permettono peraltro come visto di affrontare brillantemente il problema della stima dell'incertezza nelle predizioni e di tenere al contempo nella dovuta considerazione le strutture di correlazione spazio-temporali. Al contempo i "costi" computazionali si attestano su livelli ragionevoli soprattutto grazie all'uso di approcci efficienti in questo senso come quello INLA-SPDE usato in questo studio.

Per concludere, abbiamo proposto nell'ambito delle attività dell'obiettivo 1 del progetto PULVIRUS un modello statistico Bayesiano spazio-temporale come un nuovo strumento adatto per valutare nello spazio e nel tempo l'efficacia di politiche di risanamento dell'aria.

Come caso studio applicativo abbiamo focalizzato la nostra attenzione sulla stima della variazione relativa delle concentrazioni di NO₂ occorsa nel 2020 rispetto al 2019 con l'obiettivo di isolare l'effetto delle misure restrittive rispetto all'effetto confondente della meteorologia.

Il nostro modello non simula esplicitamente i processi chimico fisici alla base del destino in atmosfera degli inquinanti (come fanno i modelli CTM) tuttavia presenta dei vantaggi chiave rappresentati dal



piccolo volume di dati di input necessari e dalla intrinseca capacità di gestire l'incertezza associata ai valori dei parametri stimati e delle simulazioni, visualizzabili su mappe per un immediato impatto visivo degli effetti.

Abbiamo dimostrato la possibilità di ottenere con il metodo proposto un quadro credibile e matematicamente quantificabile dell'evoluzione delle concentrazioni di NO₂ in Italia al netto del fattore confondente della meteorologia.

La variabilità spatio-temporali delle concentrazioni di NO₂ nei mesi di marzo e aprile 2020 rispetto agli stessi mesi del 2019 è illustrata mediante mappe spazialmente continue e normalizzate meteorologicamente su intervalli settimanali divise per giorni feriali e festivi. I nostri risultati dimostrano che durante i mesi di marzo e aprile 2020 l'intero dominio di studio è stato caratterizzato da variazioni relative di segno negativo nelle concentrazioni di NO₂ con valori mediani di circa il 25%. I nostri risultati appaiono ragionevolmente coerenti con quelli ottenuti nell'ambito di altri studi condotti in Europa.

Generalmente le riduzioni statisticamente significative sono prevalenti nelle aree urbane rispetto a quelle rurali e montuose. L'andamento temporale che emerge dalle simulazioni settimanali mostra una chiara sincronia con l'implementazione delle misure di distanziamento e con la conseguente riduzione delle attività nel mese di marzo, mentre nel mese di aprile in particolare nella parte finale è evidente l'inizio di un parziale fenomeno di riallineamento tra le concentrazioni del 2020 e quelle del 2019. Questo aspetto era stato anticipato già dall'osservazione dei dati puntuali non aggiustati per la meteorologia (vedi figura 2).

Vale la pena osservare che non possiamo trarre sulla base del nostro modello conclusioni in merito a una relazione di causa-effetto tra lockdown e riduzione delle concentrazioni. Tuttavia, poiché i nostri risultati sono ottenuti rimuovendo l'effetto confondente della meteorologia possiamo affermare innanzitutto che le riduzioni osservate non sono attribuibili ad effetti meteorologici ma vanno attribuite ragionevolmente a una diminuzione delle emissioni che almeno in parte, considerata la sincronia tra effetti e misure di distanziamento sociale è certamente legata al lockdown. Detto questo non possiamo, sulla base dei nostri risultati, escludere che altri fattori, non adeguatamente considerati o colti dal nostro modello possano aver giocato un ruolo nelle dinamiche degli andamenti osservati. Il modello qui descritto si ispira da un punto di vista metodologico all'approccio introdotto recentemente dagli stessi autori (Fioravanti et al.,2021) per la valutazione della variabilità spaziale e temporale delle concentrazioni di PM₁₀ in Italia. Sulla base della nostra migliore conoscenza questo tipo di approccio metodologico non è mai stato applicato nel contesto dei modelli spatio-temporali



per gli studi di *intervention analysis*. Si sarebbero potuti adottare altri approcci, sempre nell'ambito della modellazione spazio-temporale. Ad esempio, lo stesso problema avrebbe potuto essere affrontato anche, prima, modellando congiuntamente le concentrazioni e quindi calcolare le differenze tra le previsioni giornaliere. Tuttavia, questa soluzione alternativa ha due importanti carenze: per prima cosa non è coerente con l'ipotesi AR(1), poiché le nostre osservazioni non sono consecutive nel tempo ma sono costituite da due intervalli discontinui a un anno di distanza uno dall'altro (marzo-aprile 2019 e marzo-aprile 2020); inoltre richiederebbe maggiori risorse di calcolo in quanto la dimensione del set di dati di input sarebbe il doppio della dimensione del set di dati di input utilizzato considerando come variabile risposta le differenze giornaliere. Inoltre, l'uso delle differenze quotidiane riduce l'effetto di multicollinearità tra i regressori e permette di includere un maggior numero di parametri nell'equazione di regressione. Per questo crediamo che il modello spazio-temporale che proponiamo rappresenti una valida soluzione applicativa per la valutazione di interventi di risanamento della qualità dell'aria a partire dai livelli di concentrazione osservati da una rete di monitoraggio della qualità dell'aria.

Un altro aspetto interessante è rappresentato dal fatto che il nostro modello consente una valutazione della variabilità spaziale delle concentrazioni di NO₂ ad alta risoluzione spaziale su un dominio molto grande come quello dell'intero territorio italiano, con un impegno di risorse di calcolo molto limitato rispetto ad altri possibili approcci; le distribuzioni a posteriori delle differenze di concentrazione possono virtualmente essere estrapolate per ogni cella della griglia. Questo aspetto può essere di particolare interesse per coloro che siano coinvolti nelle attività di *intervention analysis* o nelle analisi epidemiologiche atte a valutare variazioni e gradienti di esposizione della popolazione, in quanto la valutazione degli hot-spot urbani, la variabilità tra diverse aree urbane e il confronto tra zone rurali e contesti urbani può essere condotta a una risoluzione spaziale molto alta con uno sforzo computazionale ragionevole. In questo senso il nostro approccio può essere replicato per valutare l'eventuale effetto di qualunque tipo di misura di risanamento della qualità dell'aria sia su scala locale che su scala regionale.

La semplicità dell'approccio inoltre consente potenzialmente l'estensione a domini spaziali più grandi, ad altri inquinanti di interesse, o più in generale allo studio di fenomeni che evolvono spazialmente e temporalmente in modo continuo e dei quali sia interessante valutare la variabilità inter-annuale o inter-stagionale.



7 BIBLIOGRAFIA

- Ali, G., Abbas, S., Qamer, F. M., Wong, M. S., Rasul, G., Irteza, S. M., & Shahzad, N. (2021). Environmental impacts of shifts in energy, emissions, and urban heat island during the covid-19 lockdown across pakistan. *Journal of Cleaner Production*, 291. doi: 10.1016/j.jclepro.2021.125806
- Bao, R., & Zhang, A. (2020). Does lockdown reduce air pollution? Evidence from 44 cities in northern China. *Science of The Total Environment*, 731, 139052. Retrieved from <https://www.sciencedirect.com/science/article/pii/S0048969720325699> doi: <https://doi.org/10.1016/j.scitotenv.2020.139052>
- Bar, S., Parida, B. R., Mandal, S. P., Pandey, A. C., Kumar, N., & Mishra, B. (2021). Impacts of partial to complete COVID-19 lockdown on NO₂ and PM_{2.5} levels in major urban cities of Europe and USA. *Cities*, 117, 103308. Retrieved from <https://www.sciencedirect.com/science/article/pii/S0264275121002080> doi: <https://doi.org/10.1016/j.cities.2021.103308>
- Barré, J., Petetin, H., Colette, A., Guevara, M., Peuch, V. H., Rouil, L., ... Kouznetsov, R. (2020). Estimating lockdown induced European NO₂ changes. *Atmospheric Chemistry and Physics Discussions*, 2020, 1–28. Retrieved from <https://acp.copernicus.org/preprints/acp-2020-995/> doi: 10.5194/acp-2020-995
- Bassani, C., Vichi, F., Esposito, G., Montagnoli, M., Giusto, M., & Ianniello, A. (2021). Nitrogen dioxide reductions from satellite and surface observations during COVID-19 mitigation in Rome (Italy). *Environmental Science and Pollution Research*.
- Bauwens, M., Compornolle, S., Stavrakou, T., Müller, J. F., van Gent, J., Eskes, H., ... Zehner, C. (2020). Impact of Coronavirus Outbreak on NO₂ Pollution Assessed Using TROPOMI and OMI Observations. *Geophysical Research Letters*, 47(11).
- A Bayesian LSTM model to evaluate the effects of air pollution control regulations in Beijing, China. (n.d.). *Environmental Science and Policy*.
- Beloconi, A., Probst-Hensch, N. M., & Vounatsou, P. (2021). Spatio-temporal modelling of changes in air pollution exposure associated to the COVID-19 lockdown measures across Europe. *Science of The Total Environment*, 787, 147607. Retrieved from <https://www.sciencedirect.com/science/article/pii/S0048969721026784> doi: <https://doi.org/10.1016/j.scitotenv.2021.147607>
- Burns, J., Boogaard, H., Polus, S., Pfadenhauer, L., Rohwer, A., van Erp, A., ... Rehfuess, E. (2020). Interventions to reduce ambient air pollution and their effects on health: An abridged cochrane systematic review. *Environment International*, 135, 105400. doi: <https://doi.org/10.1016/j.envint.2019.105400>
- Cameletti, M. (2020). The Effect of Corona Virus Lockdown on Air Pollution: Evidence from the City of Brescia in Lombardia Region (Italy). *Atmospheric Environment*, 239, 117794. Retrieved from <https://www.sciencedirect.com/science/article/pii/S1352231020305288> doi: <https://doi.org/10.1016/j.atmosenv.2020.117794>
- Cameletti, M., Ignaccolo, R., & Bande, S. (2011). Comparing spatio-temporal models for particulate matter in Piemonte. *Environmetrics*, 22(8), 985-996. Retrieved from <https://onlinelibrary.wiley.com/doi/abs/10.1002/env.1139> doi: <https://doi.org/10.1002/env.1139>
- Cameletti, M., Lindgren, F., Simpson, D., & Rue, H. (2013). Spatio-temporal modeling of particulate matter concentration through the SPDE approach. *AStA Advances in Statistical Analysis*, 97(2), 109–131.



Carlos, O. n., Jose M., G.-P., & Ricardo, G.-H. (2020). Early spring near-surface ozone in Europe during the COVID-19 shutdown: Meteorological effects outweigh emission changes. *Science of The Total Environment*, 747, 141322. <https://www.sciencedirect.com/science/article/pii/S0048969720348518>

CEN-TC 264, A. q. (2012). European standard en 14211:2012 ambient air quality — standard method for the measurement of the concentration of nitrogen dioxide and nitrogen monoxide by chemiluminescence. (Tech. Rep.).

Cersosimo, A., Serio, C., & Masiello, G. (2020). TROPOMI NO₂ Tropospheric Column Data: Regridding to 1 km Grid-Resolution and Assessment of their Consistency with In Situ Surface Observations. *Remote Sensing*, 12(14). Retrieved from <https://www.mdpi.com/2072-4292/12/14/2212> doi: 10.3390/rs12142212

Chan, K. L., Khorsandi, E., Liu, S., Baier, F., & Valks, P. (2021). Estimation of Surface NO₂ Concentrations over Germany from TROPOMI Satellite Observations Using a Machine Learning Method. *Remote Sensing*, 13(5). Retrieved from <https://www.mdpi.com/2072-4292/13/5/969> doi: 10.3390/rs13050969

Chang, W., Cheng, J., Allaire, J., Sievert, C., Schloerke, B., Xie, Y., ... Borges, B. (2021). Shiny: Web application framework for r [Computer software manual]. Retrieved from <https://CRAN.R-project.org/package=shiny> R package version 1.7.1.

R Core Team (2020). R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. URL <https://www.R-project.org/>.

RStudio Team (2019). RStudio: Integrated Development for R. RStudio, Inc., Boston, MA. URL <http://www.rstudio.com/>.

Cramer, F., Shephard, G., & Heron, P. (2020). The misuse of colour in science communication. *Nat Commun*. doi: 10.1038/s41467-020-19160-7

Dacre, H. F., Mortimer, A. H., & Neal, L. S. (2020). How have surface NO₂ concentrations changed as a result of the UK's COVID-19 travel restrictions? *Environmental Research Letters*, 15(10), 104089. Retrieved from <https://doi.org/10.1088/1748-9326/abb6a2> doi: 10.1088/1748-9326/abb6a2

Diémoz, H., Magri, T., Pession, G., Tarricone, C., Tombolato, I. K. F., Fasano, G., & Zublena, M. (2021). Air Quality in the Italian Northwestern Alps during Year 2020: Assessment of the COVID-19 Lockdown Effect from Multi-Technique Observations and Models. *Atmosphere*, 12(8). Retrieved from <https://www.mdpi.com/2073-4433/12/8/1006> doi: 10.3390/atmos12081006

Donzelli, G., Cioni, L., Cancellieri, M., Llopis Morales, A., & Morales Suárez-Varela, M. M. (2020). The Effect of the Covid-19 Lockdown on Air Quality in Three Italian Medium-Sized Cities. *Atmosphere*, 11(10). Retrieved from <https://www.mdpi.com/2073-4433/11/10/1118> doi: 10.3390/atmos11101118

Dutta, V., Kumar, S., & Dubey, D. (2021). Recent advances in satellite mapping of global air quality: evidences during COVID-19 pandemic. *Environmental Sustainability*.

EEA. (2020). Air quality in Europe - 2020 Report (Tech. Rep.). European Environmental Agency (EEA). <https://www.eea.europa.eu/publications/air-quality-in-europe-2020-report>.

Fassò, A. (2013). Statistical assessment of air quality interventions. *Stochastic Environmental Research and Risk Assessment*, 27(7), 1651–1660.

Fassò, A., Maranzano, P., & Otto, P. (2021). Spatiotemporal variable selection and air quality impact assessment of covid-19 lockdown. *Spatial Statistics*, 100549. Retrieved from <https://www.sciencedirect.com/science/article/pii/S2211675321000592> doi: <https://doi.org/10.1016/j.spasta.2021.100549>



- Finazzi, F., Scott, E. M., & Fassò, A. (2013). A model-based framework for air quality indices and population risk evaluation, with an application to the analysis of scottish air quality data. *Journal of the Royal Statistical Society: Series C (Applied Statistics)*, 62(2), 287-308. doi: <https://doi.org/10.1111/rssc.12001>
- Fioravanti, G., Martino, S., Cameletti, M., & Cattani, G. (2021). Spatio-temporal modelling of PM10 daily concentrations in Italy using the SPDE approach. *Atmospheric Environment*, 248, 118192. doi: <https://doi.org/10.1016/j.atmosenv.2021.118192>
- Font, A., & Fuller, G. W. (2016). Did policies to abate atmospheric emissions from traffic have a positive effect in London? *Environmental Pollution*, 218, 463-474. doi: <https://doi.org/10.1016/j.envpol.2016.07.026>
- 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(525), 445-452.
- Gkatzelis, G. I., Gilman, J. B., Brown, S. S., Eskes, H., Gomes, A. R., Lange, A. C., ... Kiendler-Scharr, A. (2021). The global impacts of COVID-19 lockdowns on urban air pollution: A critical review and recommendations. *Elementa: Science of the Anthropocene*, 9(1). doi: 10.1525/elementa.2021.00176
- Granella, F., Reis, L. A., Bosetti, V., & Tavoni, M. (2021). COVID-19 lockdown only partially alleviates health impacts of air pollution in Northern Italy. *Environmental Research Letters*, 16(3), 035012. Retrieved from <https://doi.org/10.1088/1748-9326/abd3d2> doi: 10.1088/1748-9326/abd3d2
- Grange, S. K., & Carslaw, D. C. (2019). Using meteorological normalisation to detect interventions in air quality time series. *Science of The Total Environment*, 653, 578-588. doi: <https://doi.org/10.1016/j.scitotenv.2018.10.344>
- Grange, S. K., Lee, J. D., Drysdale, W. S., Lewis, A. C., Hueglin, C., Emmenegger, L., & Carslaw, D. C. (2021). Covid-19 lockdowns highlight a risk of increasing ozone pollution in european urban areas. *Atmospheric Chemistry and Physics*, 21(5), 4169-4185. Retrieved from <https://acp.copernicus.org/articles/21/4169/2021/> doi: 10.5194/acp-21-4169-2021
- He, G., Pan, Y., & Tanaka, T. (2020). The short-term impacts of COVID-19 lockdown on urban air pollution in China. *Nature Sustainability*, 3(12), 1005-1011.
- Hersbach, H., Bell, B., Berrisford, P., Hirahara, S., Horányi, A., Muñoz-Sabater, J., ... Thépaut, J. (2020). The ERA5 Global Reanalysis. *Q J R Meteorol Soc.*
- Hoermann, S., Jammoul, F., Kuenzer, T., & Stadlober, E. (2021). Separating the impact of gradual lockdown measures on air pollutants from seasonal variability. *Atmospheric Pollution Research*, 12(2), 84-92. doi: <https://doi.org/10.1016/j.apr.2020.10.011>
- Holman, C., Harrison, R., & Querol, X. (2015). Review of the efficacy of low emission zones to improve urban air quality in European cities. *Atmospheric Environment*, 111, 161-169. doi: <https://doi.org/10.1016/j.atmosenv.2015.04.009>
- Keller, C. A., Evans, M. J., Knowland, K. E., Hasenkopf, C. A., Modekurty, S., Lucchesi, R. A., ... Pawson, S. (2021). Global impact of COVID-19 restrictions on the surface concentrations of nitrogen dioxide and ozone. *Atmospheric Chemistry and Physics*, 21(5), 3555-3592. Retrieved from <https://acp.copernicus.org/articles/21/3555/2021/> doi: 10.5194/acp-21-3555-2021
- Kim, M., Brunner, D., & Kuhlmann, G. (2021). Importance of satellite observations for high-resolution mapping of near-surface no2 by machine learning. *Remote Sensing of Environment*, 264, 112573. Retrieved from <https://www.sciencedirect.com/science/article/pii/S0034425721002935> doi: <https://doi.org/10.1016/j.rse.2021.112573>



- Kumari, P., & Toshniwal, D. (2020). Impact of lockdown on air quality over major cities across the globe during COVID-19 pandemic. *Urban Climate*, 34, 100719. Retrieved from <https://www.sciencedirect.com/science/article/pii/S2212095520304387> doi: <https://doi.org/10.1016/j.uclim.2020.100719>
- Lee, D., Mukhopadhyay, S., Rushworth, A., & Sahu, S. K. (2016, 12). A rigorous statistical framework for spatio-temporal pollution prediction and estimation of its long-term impact on health. *Biostatistics*, 18(2), 370-385. Retrieved from <https://doi.org/10.1093/biostatistics/kxw048> doi: 10.1093/biostatistics/kxw048
- Lemoine, N. P. (2019). Moving beyond noninformative priors: why and how to choose weakly informative priors in Bayesian analyses. *Oikos*, 128(7), 912-928. doi: <https://doi.org/10.1111/oik.05985>
- Lindgren, F., & Rue, H. (2015). Bayesian Spatial Modelling with R-INLA. *Journal of Statistical Software, Articles*, 63(19), 1–25. Retrieved from <https://www.jstatsoft.org/v063/i19> doi: 10.18637/jss.v063.i19
- Malpede, M., & Percoco, M. (2020). Lockdown measures and air quality: evidence from Italian provinces. *Lett Spat Resour Sci.*, 1-10. Retrieved from <https://pubmed.ncbi.nlm.nih.gov/33758625/> doi: 10.1007/s12076-021-00267-4
- Maranzano, P., Fassò, A., Pelagatti, M., & Mudelsee, M. (2020). Statistical Modeling of the Early-Stage Impact of a New Traffic Policy in Milan, Italy. *International Journal of Environmental Research and Public Health*, 17(3). doi: 10.3390/ijerph17031088
- Marinello, S., Lolli, F., & Gamberini, R. (2021). The Impact of the COVID-19 Emergency on Local Vehicular Traffic and Its Consequences for the Environment: The Case of the City of Reggio Emilia (Italy). *Sustainability*, 13. Retrieved from <https://www.mdpi.com/2071-1050/13/1/118> doi: 10.3390/su13010118
- Martino, S., & Riebler, A. (2020). Integrated Nested Laplace Approximations (INLA). In *Wiley statsref: Statistics reference online* (p. 1-19). Retrieved from <https://onlinelibrary.wiley.com/doi/abs/10.1002/9781118445112.stat08212> doi: <https://doi.org/10.1002/9781118445112.stat08212>
- Menut, L., Bessagnet, B., Siour, G., Mailler, S., Pennel, R., & Cholakanian, A. (2020). Impact of lockdown measures to combat Covid-19 on air quality over western Europe. *Science of The Total Environment*, 741, 140426. Retrieved from <https://www.sciencedirect.com/science/article/pii/S0048969720339486> doi: <https://doi.org/10.1016/j.scitotenv.2020.140426>
- Muhammad, S., Long, X., & Salman, M. (2020). COVID-19 pandemic and environmental pollution: a blessing in disguise? *Science of The Total Environment*. Retrieved from <https://pubmed.ncbi.nlm.nih.gov/32334164/> doi:10.1016/j.scitotenv.2020.138820
- OECD. (2020). Italian regional SME policy responses (Tech. Rep.). Retrieved from <https://www.oecd.org/cfe/leed/COVID-19-Italian-regions-SME-policy-responses.pdf>
- Ott, R. W. (1990). A physical explanation of the lognormality of pollutant concentrations. *J Air Waste Manag Assoc*, 40, 1378-1383.
- Petetin, H., Bowdalo, D., Soret, A., Guevara, M., Jorba, O., Serradell, K., & Pérez García-Pando, C. (2020). Meteorology-normalized impact of the COVID-19 lockdown upon NO₂ pollution in Spain. *Atmospheric Chemistry and Physics*, 20(18), 11119–11141. Retrieved from <https://acp.copernicus.org/articles/20/11119/2020/> doi: 10.5194/acp-20-11119-2020
- Pezzagno, M., Richiedei, A., & Tira, M. (2020). Spatial planning policy for sustainability: Analysis connecting land use and ghg emission in rural areas. *Sustainability*, 12(3). Retrieved from <https://www.mdpi.com/2071-1050/12/3/947> doi: 10.3390/su12030947



- Piccoli, A., Agresti, V., Balzarini, A., Bedogni, M., Bonanno, R., Collino, E., ... Toppetti, A. M. (2020). Modeling the Effect of COVID-19 Lockdown on Mobility and NO₂ Concentration in the Lombardy Region. *Atmosphere*, 11(12). Retrieved from <https://www.mdpi.com/2073-4433/11/12/1319> doi: 10.3390/atmos11121319
- Putaud, J.-P., Pozzoli, L., Pisoni, E., Martins Dos Santos, S., Lagler, F., Lanzani, G., ... Colette, A. (2020). Impacts of the COVID-19 lockdown on air pollution at regional and urban background sites in northern Italy. *Atmospheric Chemistry and Physics Discussions*, 2020, 1–18. Retrieved from <https://acp.copernicus.org/preprints/acp-2020-755/> doi: 10.5194/acp-2020-755
- Rana, R. H., Keramat, S. A., & Gow, J. (2021). A Systematic Literature Review of the Impact of COVID-19 Lockdowns on Air Quality in China. *Aerosol and Air Quality Research*, 21. doi: 10.4209/aaqr.200614
- Remuzzi, A., & Remuzzi, G. (2020). COVID-19 and Italy: what next? *Lancet*(395), 1225–1228. doi: [https://doi.org/10.1016/S0140-6736\(20\)30627-9](https://doi.org/10.1016/S0140-6736(20)30627-9)
- Romano, B., Fiorini, L., Marucci, A., & Zullo, F. (2020). The urbanization run-up in Italy: From a qualitative goal in the boom decades to the present and future unsustainability. *Land*, 9(9). Retrieved from <https://www.mdpi.com/2073-445X/9/9/301> doi: 10.3390/land9090301
- Ruan, G., Wu, D., Zheng, X., Zhong, H., Kang, C., Dahleh, M. A., & Sivarajani, L., S. and Xie. (2020). A Cross-Domain Approach to Analyzing the Short-Run Impact of COVID-19 on the US Electricity Sector. *Joule*. Retrieved from <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC7523140/> doi: 10.1016/j.joule.2020.08.017
- Sahu, S. K., Gelfand, A. E., & Holland, D. M. (2006). Spatio-temporal modeling of fine particulate matter. *Journal of Agricultural, Biological, and Environmental Statistics*, 11(1), 61.
- Sanfelici, M. (2020). The Italian response to the COVID-19 crisis: Lessons learned and future direction in social development. *The International Journal of Community and Social Development*, 2(2), 191-210. Retrieved from <https://doi.org/10.1177/2516602620936037> doi: 10.1177/2516602620936037
- Sannino, A., D'Emilio, M., Castellano, P., Amoroso, S., & Boselli, A. (2021). Analysis of air quality during the COVID-19 pandemic lockdown in Naples (Italy). *Aerosol and Air Quality Research*, 21(1), 200381. doi: 10.4209/aaqr.2020.07.0381
- 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), 1-28.
- SNPA. (2020). Air quality in Italy (in Italian) (Vol. 17; Tech. Rep.). Roma: Italian national system for environmental protection.
- Solberg, S., Walker, S.-E., Schneider, P., & Guerreiro, C. (2021a). Quantifying the impact of the COVID-19 lockdown measures on nitrogen dioxide levels throughout Europe. *Atmosphere*, 12(2). Retrieved from <https://www.mdpi.com/2073-4433/12/2/131> doi: 10.3390/atmos12020131
- Solberg, S., Walker, S.-E., Schneider, P., & Guerreiro, C. (2021b). Quantifying the Impact of the Covid-19 Lockdown Measures on Nitrogen Dioxide Levels throughout Europe. *Atmosphere*, 12(2). Retrieved from <https://www.mdpi.com/2073-4433/12/2/131> doi: 10.3390/atmos12020131
- Sørbye, S. H., & Rue, H. (2017). Penalised complexity priors for stationary autoregressive processes. *J Time Ser Anal*, 38(6), 923-935.
- Tyagi, P., Braun, D., Sabath, B., Henneman, L., & Dominici, F. (2020). Short-term change in air pollution following the COVID-19 state of emergency: A national analysis for the United States. *medRxiv*. doi: 10.1101/2020.08.04.20168237



van Heerwaarden, C. C., Mol, W. B., Veerman, M. A., Benedict, I., Heusinkveld, B. G., Knap, W. H., ... Fiedler, S. (2021). Record high solar irradiance in Western Europe during first COVID-19 lockdown largely due to unusual weather. *Communications Earth & Environment*, 2(1), 37.

Wang, M., Liu, F., & Zheng, M. (2021). Air quality improvement from covid-19 lockdown: evidence from china. *Air Quality, Atmosphere & Health*, 14(4), 591–604.

Yeganeh, B., Hewson, M. G., Clifford, S., Tavassoli, A., Knibbs, L. D., & Morawska, L. (2018). Estimating the spatiotemporal variation of NO₂ concentration using an adaptive neuro-fuzzy inference system. *Environmental Modelling & Software*, 100, 222-235. Retrieved from <https://www.sciencedirect.com/science/article/pii/S1364815216310490> doi: <https://doi.org/10.1016/j.envsoft.2017.11.031>

Zhe, W., Itsushi, U., Keiya, Y., Syuichi, I., Xueshun, C., Wenyi, Y., & Zifa, W. (2021). Impacts of COVID-19 lockdown, Spring Festival and meteorology on the NO₂ variations in early 2020 over China based on in-situ observations, satellite retrievals and model simulations. *Atmospheric Environment*, 244, 117972. Retrieved from <https://www.sciencedirect.com/science/article/pii/S1352231020307068> doi: <https://doi.org/10.1016/j.atmosenv.2020.117972>

Zheng, X., Guo, B., He, J., & Chen, S. X. (2021). Effects of corona virus disease-19 control measures on air quality in North China. *Environmetrics*, 32(2), e2673. Retrieved from <https://onlinelibrary.wiley.com/doi/abs/10.1002/env.2673> doi: <https://doi.org/10.1002/env.2673>