



UNIVERSITÀ DEGLI STUDI DI SALERNO

**Department of Industrial Engineering**

Ph.D. Course in Industrial Engineering  
(XV Cycle-New Series, XXIX Cycle)

**Tesi di dottorato in:**

**Metodi Fisico Matematici Avanzati per  
l'Implementazione di Modelli Previsionali Applicabili  
a Fenomeni Acustici e di Interesse Ingegneristico**

**- Fisica Applicata -**

**Supervisor**

*Prof. Joseph Quartieri*

**Ph.D. student**

*Ing. Carmine Tepedino*

**Ph.D. Course Coordinator**

*Prof. Ing. Ernesto Reverchon*

**ANNO ACCADEMICO 2016-2017**





*Filosofo significa colui che cerca di sapere...questa ricerca esige due condizioni: la solitudine che ci costringe a pensare e parlare con noi stessi e la relazione con gli altri...alla propria ricerca, alla propria vita, hanno contribuito molte persone, anche a distanza....Dal modo in cui mi rivolgo alle altre persone le educo a capire: dipende da come le tratto, a qualunque titolo...il problema non è educare, è provocare la reazione dell'altro per renderselo compagno nella ricerca.*  
(Aldo Masullo)



**Scientific Referees**

*Prof. Ing. Nikos E. Mastorakis*

*Prof. Ing. Fabrizio Memola Capece Minutolo*

*Prof. Ing. Vincenzo Sergi*

*Prof. Ing. Claudio Rafanelli*

La data prevista per la discussione della tesi è il 30\marzo\2017.

Fisciano, 16\marzo\2017. **ISBN 88 – 7897 – 90 - 5**

# Sommario

<b>Sommario .....</b>	<b>5</b>
<b>Introduzione.....</b>	<b>9</b>
<b>Modelli deterministici per l'analisi e la previsione di serie storiche.....</b>	<b>13</b>
1.1 Sviluppo di un modello deterministico per l'analisi di serie storiche e applicazione a livelli acustici di rumore _____	15
1.1.1 Struttura matematica del modello	16
1.1.2 Analisi dei dati: Viale Bocchetta -giorno-	19
1.1.3 Calibrazione sui primi 150 dati e validazione sui seguenti 171 dati	20
1.1.4 Calibrazione su di un set di dati crescente e validazione su 3 differenti intervalli da 50 dati	22
1.1.5 Calibrazione su di un set di dati crescente verso il passato e validazione sugli stessi 50 dati osservati	26
1.1.6 Discussione sui risultati ottenuti	30
1.2 Analisi e previsione di rumore acustico con l'utilizzo di un modello a stagionalità multipla _____	31
1.2.1 Struttura matematica di un modello a stagionalità multipla	32
1.2.2 Analisi dei dati: Viale Bocchetta notte	36
1.2.3 Progettazione del modello a doppia stagionalità	39
1.2.4 Analisi dell'errore	41
1.2.5 Discussione sui risultati ottenuti	43
1.3 Un modello di previsione basato sull'analisi delle serie storiche applicato al consumo di energia elettrica _____	45
1.3.1 Presentazione del modello	46
1.3.2 Analisi dei dati	47
1.3.3 Calibrazione sul dataset del 2011	50
1.3.4 Calibrazione sul dataset del 2011 e del 2012	54
1.3.5 Analisi dell'errore e validazione	59
1.3.6 Discussione sui risultati ottenuti	63

## **Modelli stocastici stagionali auto-regressivi a media mobile ..... 65**

2.1 Confronto tra un modello deterministico di decomposizione e un modello ARIMA stagionale per l'analisi di serie storiche applicati alla previsione della rumorosità di un aeroporto _____	67
2.1.1 Analisi dei dati: aeroporto internazionale di Nizza	68
2.1.2 Richiamo ai modelli di decomposizione deterministici	70
2.1.3 Modelli ARIMA stagionali	71
2.1.4 Metodi per la valutazione dell'accuratezza dei modelli	72
2.1.5 Dettagli e risultati del modello DD-TSA	72
2.1.6 Dettagli e risultati del modello SARIMA	74
2.1.7 Diagnostica dei modelli e analisi dei residui	75
2.1.8 Discussione sui risultati ottenuti	77
2.2 Integrazione di metodi ARIMA e modellazione software per la previsione della velocità del vento e la realizzazione di mappe di rumorosità in un parco eolico _____	79
2.2.1 Previsione della velocità del vento mediante un modello ARIMA	81
2.2.2 Mappa di rumorosità dell'area in presenza del vento previsto	85
2.2.3 Discussione sui risultati ottenuti	87

## **Modelli previsionali ibridi ..... 89**

3.1 Un modello ibrido per la previsione di rumorosità acustica basato su metodi di decomposizione deterministici e reti neurali artificiali __	91
3.1.1 Richiamo al metodo di decomposizione deterministico	92
3.1.2 Reti neurali artificiali	94
3.1.3 Analisi preliminare del set di dati di calibrazione	95
3.1.4 Dettagli del modello DD-TSA	99
3.1.5 Dettagli del primo modello di rete neuronale ANN(t-1)	100
3.1.6 Dettagli del secondo modello di rete neuronale ANN(t-7)	102
3.1.7 Confronto dei modelli tramite grafici della serie storica	105
3.1.8 Valutazione degli errori di previsione sui dati di calibrazione	107
3.1.8 Analisi di prestazione dei modelli	111
3.1.9 Valutazione e analisi degli errori sul set di dati di validazione	115
3.1.10 Discussione sui risultati ottenuti	118

---

<b>Modelli di Poisson non omogenei applicati a dati acustici.....</b>	<b>121</b>
4.1 Analisi di dati di rumorosità aeroportuale usando un modello di Poisson non omogeneo con un <i>change-point</i> .....	123
4.1.1 Descrizione del modello matematico .....	124
4.1.2 Inferenza statistica .....	125
4.1.3 Applicazione ai livelli di rumorosità dell'aeroporto di Nizza .....	126
4.1.4 Discussione sui risultati ottenuti .....	132
<b>Conclusioni.....</b>	<b>135</b>
<b>Elenco completo pubblicazioni del candidato .....</b>	<b>139</b>
<b>Referenze.....</b>	<b>142</b>





## **Introduzione**



In diversi ambiti scientifici, nell'ingegneria, nella fisica applicate, nelle discipline economiche e finanziarie risulta di grande interesse lo sviluppo di modelli atti a produrre previsioni dell'andamento dei fenomeni desunti da serie storiche univariate mediante l'analisi della successione di dati osservati equidistanti nel tempo. Le tecniche implementate nel presente lavoro di tesi possono essere classificate in due distinte tipologie, differenti ma complementari: una basata sull'analisi delle serie storiche delle misure di interesse, l'altra su distribuzioni di Poisson per gli eventi di superamento di una soglia stabilita. La modellazione delle serie storiche seguita in questo elaborato è realizzata nel dominio del tempo e dunque si farà largo uso della massimizzazione della funzione di autocorrelazione al fine di indagare eventuali periodicità presenti nei dati.

Nel primo capitolo la validità di siffatti modelli sarà testata su un set di dati di rumore ambientale raccolti nella città di Messina. Le misurazioni si riferiscono a livelli acustici diurni e notturni, rilevati presso una stazione di monitoraggio predisposta dall'amministrazione locale e resi pubblici su apposita piattaforma web. Da questo set di dati, sono stati estratti diversi intervalli per la calibrazione dei modelli, al fine di testarne la validità su misurazioni reali (mediante confronto tra dato osservato e dato previsto) e di studiarne la sensibilità rispetto alla variazione dei parametri (soglia di riferimento, frequenza degli eventi, periodicità, ecc.). Per l'analisi delle serie storiche sono state sviluppate tecniche deterministiche basate sulla decomposizione nelle componenti di trend e stagionali di una sequenza di dati osservata. Si è in seguito ottenuto un potenziamento del modello di previsione e analisi delle serie storiche: in particolare si è analizzato un set di dati di assorbimento di energia elettrica dovuto al sistema di trasporto pubblico della città di Sofia, migliorando l'estrazione di informazioni dalla serie e le prestazioni grazie all'introduzione di un ulteriore coefficiente di stagionalità.

Successivamente nel secondo capitolo sono stati adottati modelli stocastici stagionali autoregressivi a media mobile (SARIMA): ci si è concentrati sull'implementazione di questi modelli previsionali per la modellazione della velocità del vento in un sito dove è installato un impianto per la produzione elettrica mediante aerogeneratori. In seguito si sono applicati modelli per la previsione dell'inquinamento acustico prodotto dal parco eolico investito da vento ad una certa velocità.

Nel terzo capitolo si è migliorata l'integrazione di tecniche previsionali lineari e non lineari mediante reti neurali artificiali; in particolare lo stato dell'arte per i modelli previsionali basati sull'analisi di serie storiche sarà raggiunto con un modello ibrido costruito sull'utilizzo in cascata di metodi deterministici basati sulla scomposizione della serie in componenti di trend e stagionalità seguiti da modellazione tramite reti neurali artificiali per una migliore previsione della parte non lineare della serie.

Infine nel quarto capitolo sarà sviluppato un modello di previsione per eventi di superamento di soglie di inquinamento acustico. Tale modello è basato sull'assunzione che gli eventi di superamento sono distribuiti secondo una distribuzione di Poisson non omogenea. Questo approccio può essere a sua volta perseguito con tecniche frequentiste o bayesiane per la stima dei parametri della "Probability Density Function" (PDF). In particolare è stato studiato un dataset di misurazioni fonometriche acquisite in prossimità dell'aeroporto internazionale di Nizza (Francia): il modello previsionale realizzato prevede l'introduzione della metodologia "change-point" singolo per la stima dei parametri della distribuzione. Tali parametri sono stati stimati grazie al campionamento Monte-Carlo Markov-Chain basato su assunzioni di statistica bayesiana.



**Modelli deterministici per l'analisi e la  
previsione di serie storiche**



## **1.1 Sviluppo di un modello deterministico per l'analisi di serie storiche e applicazione a livelli acustici di rumore**

Gli agglomerati urbani si sviluppano e crescono velocemente in accordo ad un piano regolatore che dovrebbe razionalizzare l'espansione dal punto di vista industriale, della logistica e dei trasporti [1]. Questa crescita è legata a problemi ambientali che è necessario trattare con cautela, come inquinamento dell'aria, rumore acustico, campi elettromagnetici e molti altri. In generale l'impatto ambientale deve essere tenuto in conto quando si definiscono le politiche di pianificazione urbana a causa del rischio collegato all'esposizione ad un'alta rumorosità (si veda ad esempio [2]).

Per quanto riguarda l'inquinamento acustico, deve essere considerate che esso ha una natura fortemente casuale ed è difficile riuscirlo a descrivere in termini di sorgenti, propagazione e persistenza. È necessario da un lato avere un'ampia rete di apparati di misura, dall'altro strumenti avanzati matematici, statistici e probabilistici. La forte esigenza di monitorare le emissioni acustiche si contrappone agli alti costi di installazione e manutenzione dei misuratori di livello sonoro e dei relativi accessori per le acquisizioni di lungo termine. Questa è la ragione per la quale diversi modelli previsionali sono stati sviluppati in letteratura. Ad esempio, per quanto riguarda la rumorosità prodotta dal traffico veicolare, i primi modelli sono apparsi negli anni 60 ed erano tipicamente basati su tecniche di regressione. In [3] è presentata una dettagliata comparazione tra la regolamentazione di diverse nazioni, mentre in [4] i modelli di previsione sono confrontati con dati sperimentali. Il caso dei modelli di traffico veicolare mostra che è molto difficile ottenere un modello statistico di validità generale (basato su dati misurati), capace di fornire previsioni da poter essere usate in diverse nazioni e ambienti con differenti condizioni al contorno. In [5-8] e nelle referenze riportate in questi, queste difficoltà sono largamente discusse e un approccio dinamico è suggerito per superare le limitazioni dei modelli usuali. Inoltre molto spesso i modelli più usati adottano una base dei tempi oraria che non è sempre estendibile facilmente ai livelli di rumore giornalieri.

In questo paragrafo viene presentato un approccio al problema significativamente differente, basato su un metodo matematico, l'analisi delle serie storiche (TSA) (vedere ad esempio [9,10]), metodo capace di riprodurre l'andamento di una serie di dati e dare previsioni per i valori futuri del rumore acustico. L'analisi è eseguita su di una ampia raccolta di misurazioni del rumore acustico nella città di Messina (Italia). In questo caso analizzato la rumorosità è causata principalmente dal flusso di traffico veicolare e viene evidenziata una interessante caratterizzazione in termini di periodicità e bassa variabilità.

L'affidabilità del modello sarà discussa in termini di differenza tra i valori misurati e quelli predetti. Inoltre l'analisi degli errori di previsione in funzione dell'ampiezza e numerosità dei valori per la calibrazione del modello fornirà interessanti indicazioni per un miglioramento della tecnica previsionale.

### 1.1.1 Struttura matematica del modello

I modelli di analisi delle serie storiche (TSA) sono modelli matematici capaci di riprodurre l'andamento di una certa serie di dati e di prevederne i valori futuri. Questi modelli sono ampiamente utilizzati in diversi settori come ad esempio l'economia, la fisica, l'ingegneria e la matematica (si veda ad esempio [11-13]).

I modelli TSA hanno due obiettivi generali: prima di tutto l'identificazione delle caratterizzazioni intrinseche dei dati considerati, questi ultimi rappresentano il fenomeno studiato; in seguito la possibilità di predire l'andamento futuro della serie di dati osservata. A tal fine esistono differenti metodologie, alcune delle quali sono state studiate approfonditamente in letteratura (si veda ad esempio [14]).

Le tecniche di TSA sono ampiamente adottate quando i dati seguono andamenti stagionali ricorrenti. Una procedura generale può essere riassunta come segue:

- Rilevamento di un eventuale effetto stagionale nel set di dati
- Valutazione della periodicità opportuna
- *Smoothing* (rimozione della periodicità) della serie storica
- Valutazione del *trend* e della stagionalità
- Progettazione finale del modello

La presenza di una periodicità nella serie storica può essere confermata mediante la valutazione del coefficiente di autocorrelazione:

$$\rho(k) = \frac{\sum_{t=1}^{n-k} (x_t - \bar{x}_{s1})(x_{t+k} - \bar{x}_{s2})}{\sqrt{\sum_{t=1}^{n-k} (x_t - \bar{x}_{s1})^2} \sqrt{\sum_{t=1}^{n-k} (x_{t+k} - \bar{x}_{s2})^2}}, \quad (I.1)$$

nella quale  $x_t$  è il valore della misurazione in  $t$ ,  $n$  è il numero di periodi considerati,  $k$  è il ritardo, ossia la periodicità considerata, e

$$\bar{x}_{s1} = \frac{\sum_{t=1}^{n-k} x_t}{n-k} \quad ; \quad \bar{x}_{s2} = \frac{\sum_{t=1}^{n-k} x_{t+k}}{n-k}. \quad (I.2)$$

La massimizzazione della funzione di autocorrelazione è un utile strumento per valutare il valore più appropriato per la periodicità dei dati. L'andamento dei dati (*trend*) in seguito può essere studiato tramite strumenti di regressione applicati sulle misure reali o sui valori della media mobile che sono dati non influenzati più dalla stagionalità.

La previsione a questo punto può essere ottenuta le componenti del modello, definendo modelli TSA additivi o moltiplicativi.

L'assunzione teorica generale del modello TSA qui presentato è che il dato osservato  $Y_t$ , ad ogni periodo  $t$ , è dato da:

$$Y_t = T_t \bar{S}_i + e_t, \quad (I.3)$$

nella quale  $T_t$  è il trend,  $\bar{S}_i$  è il coefficiente dell'effetto stagionale (definite di seguito) e  $e_t$  è la componente irregolare, non prevedibile deterministicamente. È doveroso sottolineare che l'indice del periodo  $t$  varia da 1 a  $n$ , il numero totale dei periodi, e  $i$  varia da 1 a  $k$ , il coefficiente di ritardo, assumendo che l'effetto stagionale è periodico. In particolare, come sarà spiegato di seguito, per un dato  $t$ , se  $t < k$ ,  $i$  è il resto del rapporto tra  $t+k$  e  $k$ ; se  $t=k$ , allora  $i=k$ ; se  $t > k$ ,  $i$  è il resto del rapporto tra  $t$  e  $k$ . Ad esempio, nel caso presentato, assumendo una periodicità settimanale,  $i$  varierà tra 1 a 7, e rappresenterà ciascun giorno della settimana (Lunedì, Martedì, ecc...).

Una prima formula per la previsione puntuale del modello  $\hat{Y}_t$  è data dalla moltiplicazione tra il trend e il coefficiente di stagionalità:

$$\hat{Y}_t = T_t \bar{S}_i . \quad (\text{I.4})$$

Il modello considera che la previsione puntuale ad un dato periodo è la combinazione di una componente di trend, cioè l'andamento di lungo periodo delle misurazioni, e una correzione a causa dello specifico periodo per il quale la previsione è fatta.

In questa sezione è stata adottata una media mobile per rimuovere la stagionalità dalla serie di dati. La scelta è ricaduta su di una media mobile centrata con ampiezza data dal ritardo (periodicità) ipotizzato. I dati studiati suggeriscono una periodicità di 7 periodi (giorni), in accordo ad una periodicità settimanale dell'emissione di rumore da traffico veicolare. Questa periodicità è stata validata dalla stima del coefficiente di autocorrelazione, come riportato nella sezione seguente.

Dunque, l'effetto stagionale  $S_t$  ad un dato periodo  $t$ , è ottenuto dal rapporto tra il valore reale  $Y_t$  e il valore della media mobile  $M_t$ . Si ricorda che per un set di dati di  $n$  periodi,  $n - k + 1$  valori sono disponibili per la media mobile centrata e, conseguentemente, per l'effetto stagionale,  $S_t$ .

$$S_t = \frac{Y_t}{M_t} . \quad (\text{I.5})$$

Un coefficiente stagionale  $\bar{S}_i$ , valutato su tutti i periodi omologhi, è stato stimato mediando l'effetto stagionale, come segue:

$$\bar{S}_i = \frac{\sum_{t=0}^{m_i-1} S_{t+lk}}{m_i} , \quad (\text{I.6})$$

nella quale  $m_i$  è il numero di  $i$ -esimi periodi omologhi (nel nostro caso, il numero di lunedì, martedì, ecc...) in tutto l'intervallo di tempo considerato.

La componente di trend è stata calcolata con l'ausilio di una regressione lineare:

$$T_t = b_0 + b_1 t . \quad (\text{I.7})$$

I coefficienti sono stati valutati sui dati della media mobile centrata descritta sopra.

Il termine  $e_t$  è utilizzato per tenere in conto l'irregolarità della serie di dati e può essere valutata durante la fase di calibrazione del modello, cioè quando sono disponibili i dati reali, considerando la differenza tra i dati reali e i valori previsti ad un determinato periodo  $t$ :

$$e_t = Y_t - \hat{Y}_t . \quad (I.8)$$

Assumendo che la componente irregolare è distribuita secondo una normale, la sua media coincide con la moda, ossia il valore più probabile. Dunque la media dell'errore può essere aggiunta alle previsioni allo scopo di migliorare l'affidabilità del modello.

Il risultato finale è un modello TSA misto: moltiplicativo tra trend e stagionalità e additivo per il termine irregolare.

Questo modello TSA può essere calibrato (ossia stimare i parametri e coefficienti) su di un dato intervallo temporale, in accordo alla procedura descritta in precedenza, e in seguito può essere validato su di un successivo intervallo di dati, non usati nella fase di calibrazione, confrontando i valori previsti con le misure reali per ogni periodo. Nel prosieguo della trattazione sarà presentato un confronto tra una diversa numerosità e collocazione temporale dei dati di calibrazione e validazione.

Al fine di stimare l'efficacia del modello, la caratterizzazione statistica della differenza tra il dato reale e la previsione puntuale (errore) è stata studiata, sia nella fase di calibrazione che in quella di validazione. Verrà presentato l'istogramma di frequenza degli errori, insieme alle statistiche come media, deviazione standard, mediana, minimo e massimo. Inoltre gli indici di asimmetria e curtosi per valutare la normalità della distribuzione degli errori.

Misure dell'errore quantitative sono date dal "Mean Percentage Error" (MPE) e dal "Coefficient of Variation of the Error" (CVE), in accordo alle formule seguenti:

$$MPE = \frac{\sum_{t=1}^n \left( \frac{Y_t - \hat{Y}_t}{Y_t} \right) 100}{n} , \quad (I.9)$$

$$CVE = \frac{\sqrt{\frac{\sum_{t=1}^n (e_t)^2}{n-1}}}{\bar{Y}} , \quad (I.10)$$

nelle quali  $\bar{Y}$  è la media dei dati reali relativi all'intervallo temporale considerato.

La formula (I.9) (MPE) fornisce una valutazione della "distorsione" dell'errore, mentre la formula (I.10) (CVE) fornisce la "dispersione" dell'errore. L' MPE è in grado di descrivere se il modello sovrastima o sottostima (in media) i dati reali, mentre il CVE considera le variazioni dal valore reale in valore assoluto.

Il "coefficiente di variazione" più generale è invece definito come  $CV = s/m$ , nella quale  $s$  è la deviazione standard del campione  $\{|m(h_i) - \hat{m}(h_i)| : i = 1, 2, \dots, K\}$  e  $m$  è la sua media.

### 1.1.2 Analisi dei dati: Viale Bocchetta -giorno-

Il set di dati usato in questa sezione è relativo ad una campagna di misurazioni di lunga durata progettata e messa in pratica dal comune di Messina. La città ha circa 240000 abitanti, e insieme ai problemi abituali di inquinamento atmosferico di una media città con un porto commerciale, un alto flusso di traffico veicolare e alcuni insediamenti industriali, è presente un rilevante inquinamento acustico dovute alle infrastrutture di trasporto. L'amministrazione locale ha deciso di installare alcune stazioni di monitoraggio, equipaggiate con fonometri di prima classe, al fine di misurare le fluttuazioni di lungo termine del rumore acustico. Questi dati sono stati messi a disposizione dalla locale amministrazione tramite piattaforma web [15].

In particolare sono stati utilizzati I dati raccolti dalla piattaforma di monitoraggio di Viale Bocchetta, considerando il livello equivalente ponderato con curva A [16-17], definito come:

$$L_{Aeq,T} = 10 \log \left[ \frac{1}{T} \int_0^T \frac{p_A^2(t)}{p_0^2} dt \right], \quad (I.11)$$

relativo ad un intervallo giornaliero di 16 ore, dalle 6:00 alle 22:00. L'intervallo di acquisizione considerato va dall' 11 maggio 2007 al 26 marzo 2008, ovvero 321 giorni/periodi.

Le statistiche riassuntive dell'intero set di dati sono mostrate nella tabella I.1.

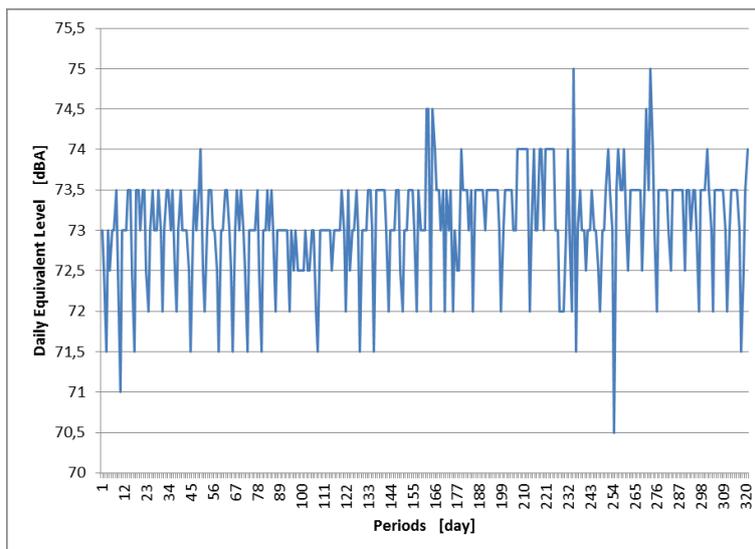
**Tab. I.1:** Statistiche riassuntive dell'intero set di dati.

<b>Media</b> <b>[dBA]</b>	<b>Dev. Std.</b> <b>[dBA]</b>	<b>Mediana</b> <b>[dBA]</b>	<b>Min</b> <b>[dBA]</b>	<b>Max</b> <b>[dBA]</b>
73.07	0.65	73.5	70.5	75.0

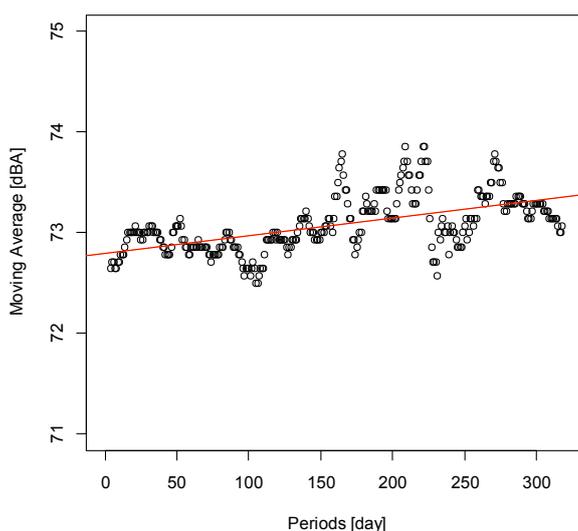
A causa del fatto che i dati sono fortemente correlati al flusso di traffico veicolare, è presente un'evidente caratterizzazione stagionale.

Una periodicità pari a 7 giorni è stata ipotizzata, in accordo ad una stagionalità settimanale. La scelta sembra ragionevole guardando la serie storica dei dati in figura I.1 e considerando che durante i fine-settimana si osserva un flusso di traffico inferiore. Il coefficiente di autocorrelazione assume un valore pari a 0.58 per un ritardo pari a 7 giorni.

Il trend è stato ottenuto rimuovendo la stagionalità con la media mobile e valutando sui valori ottenuti una regressione lineare come mostrato in figura I.2.



**Fig. I.1:** Serie storica dei livelli equivalenti diurni nell'intervallo temporale completo, dall'11 maggio 2007 al 26 marzo 2008, ossia 321 giorni.



**Fig. I.2:** Media mobile centrata, con passo uguale a 7, del livello equivalente diurno nell'intervallo temporale completo. La linea rossa rappresenta la regressione lineare.

### 1.1.3 Calibrazione sui primi 150 dati e validazione sui seguenti 171 dati

La prima analisi è stata eseguita calibrando i parametri del modello sui primi 150 dati e validando i risultati sui rimanenti 171 giorni della serie.

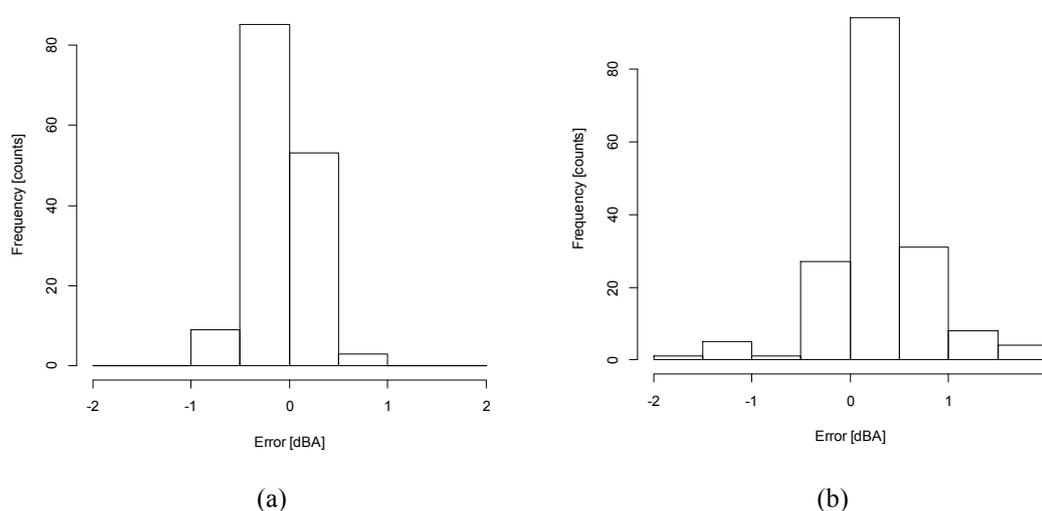
Durante la fase di calibrazione, l'errore (differenza tra valore reale e valore previsto) è stato diagrammato in un istogramma di frequenza (Fig. I.3(a)). La valutazione di asimmetria e curtosi conferma l'ipotesi di distribuzione normale per gli errori.

Il modello così calibrato è stato usato per prevedere i dati della rimanente parte della serie storica (171 periodi). In particolare è stato stabilito un intervallo di previsione  $PI$  assumendo una semi ampiezza pari a 2 deviazioni standard ( $s_e$ ):

$$PI = \hat{Y}_t + m_e \pm 2s_e, \quad (I.12)$$

Nella quale  $m_e$  è l'errore medio valutato (come anche  $s_e$ ) durante la fase di calibrazione.

Questi risultati sono mostrati nella figura I.4, nella quale la linea blu rappresenta i dati reali, la rossa è la previsione puntuale del modello (centro dell'intervallo di previsione) e le due linee tratteggiate color porpora sono i limiti superiore e inferiore dell'intervallo.



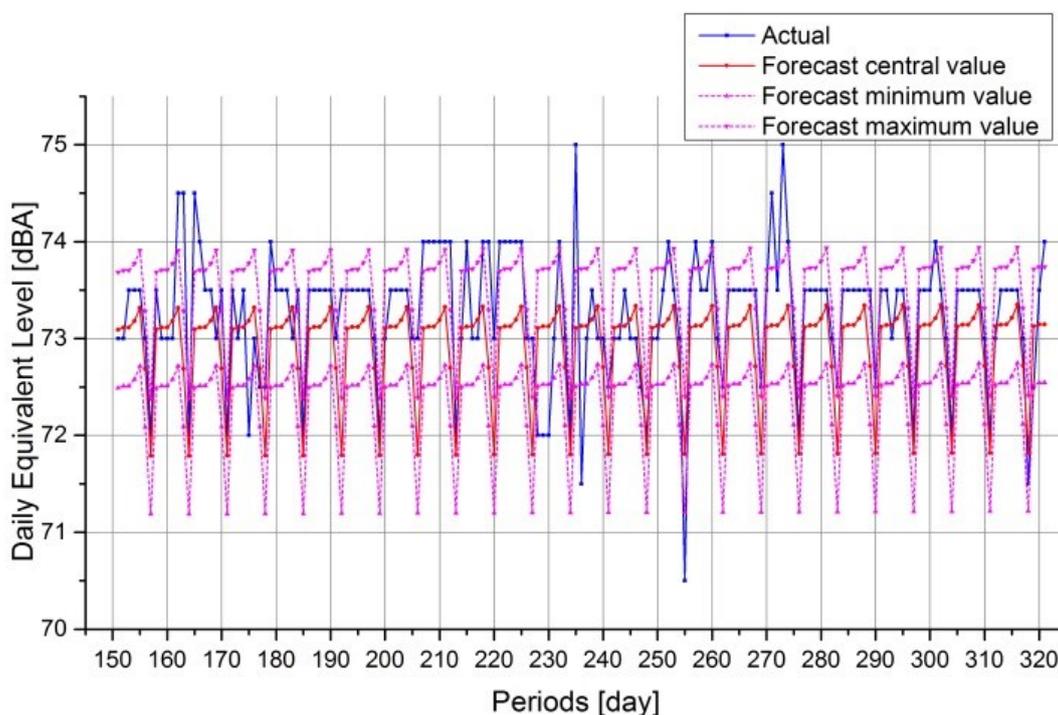
**Fig. I.3:** (a) Istogramma di frequenza degli errori calcolati sui primi 150 dati durante la calibrazione del modello. (b) Istogramma di frequenza degli errori calcolati sugli ultimi 171 dati durante la fase di validazione del modello.

**Tab. I.2:** Statistiche riassuntive della distribuzione degli errori valutati sia nella fase di calibrazione che in quella di validazione.

Fase	Media [dBA]	Dev.Std. [dBA]	Mediana [dBA]	Min [dBA]	Max [dBA]	skew	kurt
Calibrazione	0.00	0.30	-0.09	-0.81	0.72	-0.03	-0.10
Validazione	0.33	0.52	0.32	-1.63	1.89	-0.29	2.57

La validazione sui successivi 171 dati fornisce buoni risultati, come mostrato dalle statistiche della distribuzione dell'errore, mostrate nella tabella I.2. Una media dell'errore di 0.33 dBA evidenzia una leggera sottostima delle previsioni rispetto ai dati reali. La deviazione standard calcolata in fase di calibrazione di 0.30 dBA fornisce un intervallo di confidenza con semi-ampiezza di 0.6 dBA.

Gli indici di asimmetria e curtosi (rispettivamente indicati con le abbreviazioni skew e kurt in tabella I.2) aiutano a valutare la normalità della distribuzione degli errori, che nel caso specifico, appare un' ipotesi verificata.



**Fig. I.4:** Intervallo di previsione del modello. La linea blu rappresenta I dati reali, la rossa è la previsione media del modello e le linee tratteggiate in rosa sono I limiti inferiore e superiore dell'intervallo.

#### *1.1.4 Calibrazione su di un set di dati crescente e validazione su 3 differenti intervalli da 50 dati*

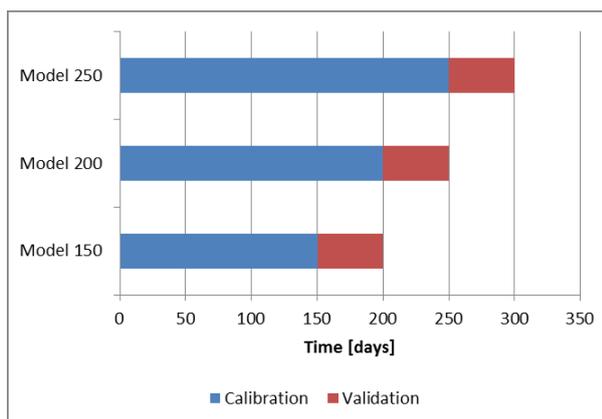
La successiva analisi prevede un confronto tra i risultati ottenuti facendo crescere il set di dati di calibrazione e validando il modello sui 50 dati immediatamente successivi.

I dati di calibrazione e i rispettivi intervalli di validazione sono riportati nella figura I.5.

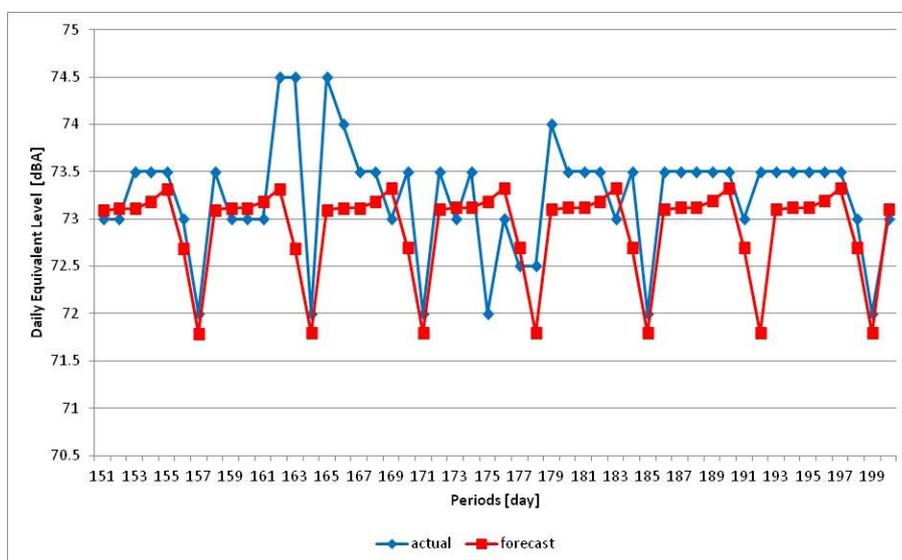
I grafici della previsione del modello nei tre diversi casi sono riportati nelle figure I.6, I.7 e I.8, mentre nella tabella I.3 sono riassunte le statistiche principali degli errori nei tre scenari di validazione.

Le figure I.6, I.7 e I.8 mostrano che c'è in genere accordo tra le previsioni del modello e i dati reali, specialmente dopo la terza fase (Fig. I.8), utilizzando dunque l'intervallo di validazione più ampio. I risultati sono confermati dalle statistiche di ogni scenario riassunte nella tabella I.3. Il primo passo dell'incremento del set di dati di calibrazione (da 150 a 200) produce un abbassamento della media dell'errore ma una crescita della deviazione standard. Nell'ultimo scenario con set di calibrazione di 250 periodi, la media dell'errore è approssimativamente la stessa, ma decresce la deviazione standard così come atteso. Gli istogrammi della distribuzione degli errori relativi ai tre scenari sono riportati in figura I.9.

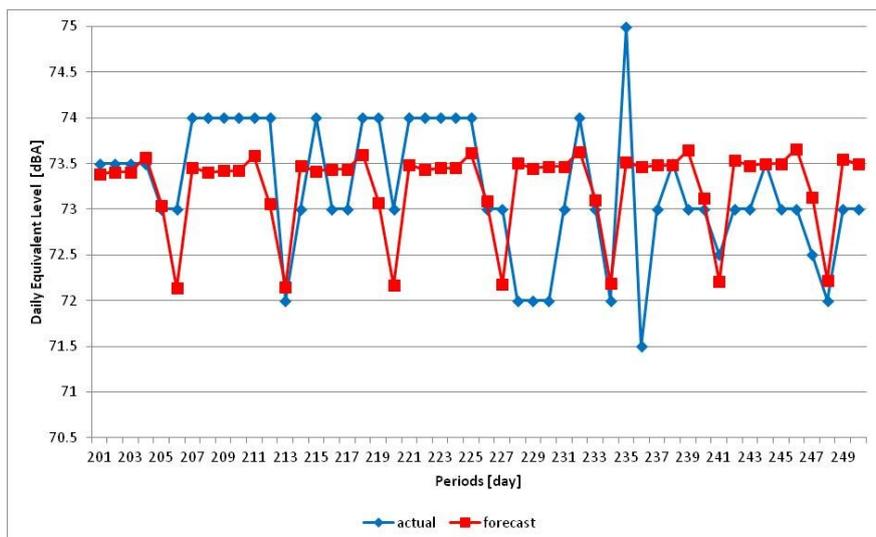
L'assunzione di distribuzione normale degli errori è più o meno rispettata cambiando l'ampiezza del set di dati di calibrazione e traslando il periodo di validazione, eccetto che per il secondo scenario. Questi risultati sulla media e sulla deviazione standard dell'errore, mostrati nella figura I.10, possono essere spiegati considerando le statistiche di ciascun intervallo di validazione in tabella I.4, in particolare la dispersione dei dati. La deviazione standard infatti mostra una crescita nel secondo set di validazione (quando cioè il modello è calibrato su 200 periodi), causando una serie storica più variabile. In generale infatti se la deviazione standard nei dati di validazione cresce, l'assunzione di distribuzione normale degli errori può essere facilmente violata.



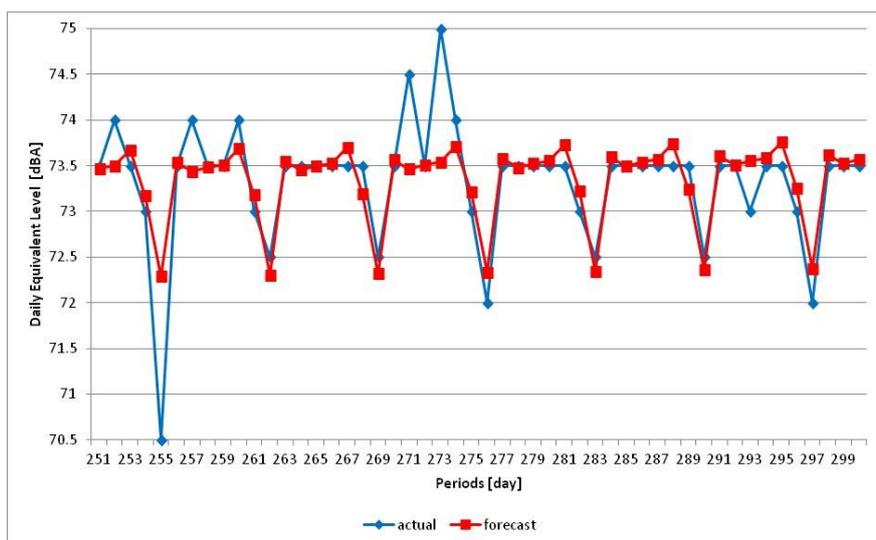
**Fig. I.5:** Set di dati di calibrazione crescenti e relativi intervalli di validazione.



**Fig. I.6:** Grafico comparativo tra le previsioni, ottenute calibrando il modello sui primi 150 dati, e i successivi 50 dati realmente osservati.



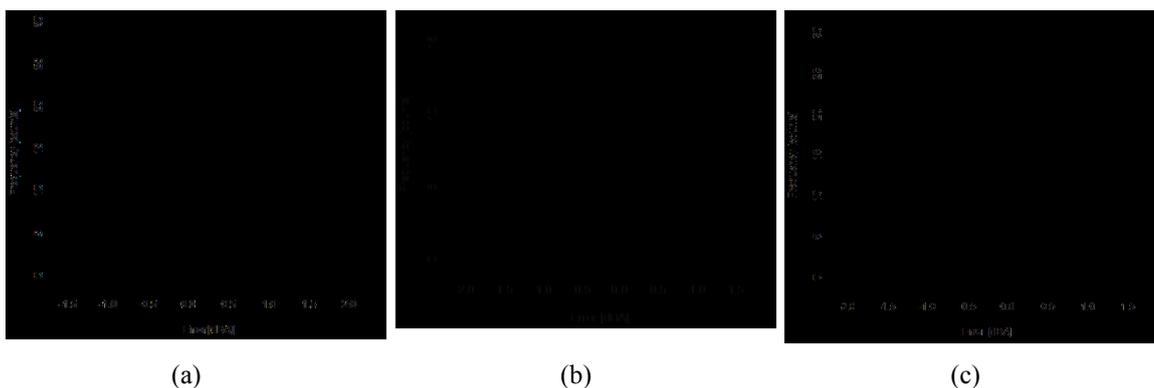
**Fig. I.7:** Grafico comparativo tra le previsioni, ottenute calibrando il modello sui primi 200 dati, e i successivi 50 dati realmente osservati.



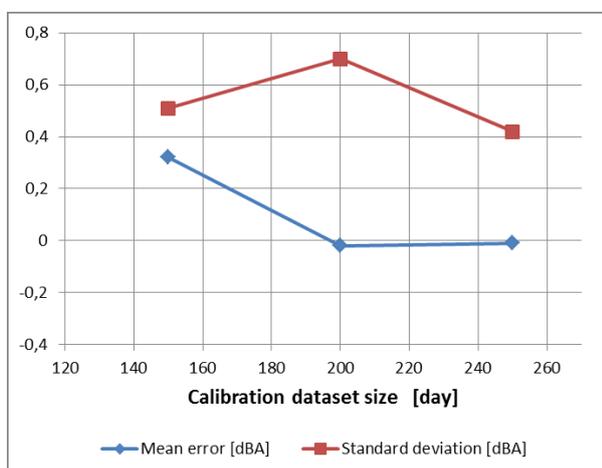
**Fig. I.8:** Grafico comparativo tra le previsioni, ottenute calibrando il modello sui primi 250 dati, e i successivi 50 dati realmente osservati.

**Tab. I.3:** Comparazione tra le statistiche della distribuzione degli errori durante la fase di validazione in funzione dell'ampiezza del set di dati di calibrazione.

Numerosità dei dati di calibrazione	Media [dBA]	Dev.Std. [dBA]	Mediana [dBA]	Min [dBA]	Max [dBA]
150	0.32	0.51	0.31	-1.19	1.81
200	-0.02	0.70	-0.02	-1.96	1.48
250	-0.01	0.42	-0.04	-1.79	1.46



**Fig. I.9:** Istogramma di frequenza degli errori calcolati durante la validazione del modello: (a) a sinistra validazione sui dati dal 151° al 200°; (b) al centro validazione sui dati dal 201° al 250°; (c) a destra validazione sui dati dal 251° al 300°.



**Fig. I.10:** Media e deviazione standard della distribuzione degli errori ottenute validando il modello su 50 dati reali in funzione della numerosità dei dati di calibrazione.

**Tab. I.4:** Statistiche riassuntive dei dati di validazione usati per testare il modello calibrato con una diversa numerosità dei dati di calibrazione.

Dati di validazione	Media [dBA]	Dev.Std [dBA]	Mediana [dBA]	Min [dBA]	Max [dBA]
151-200	73.23	0.62	73.5	72.0	74.5
201-250	73.23	0.74	73.0	71.5	75.0
251-300	73.33	0.67	73.5	70.5	75.0

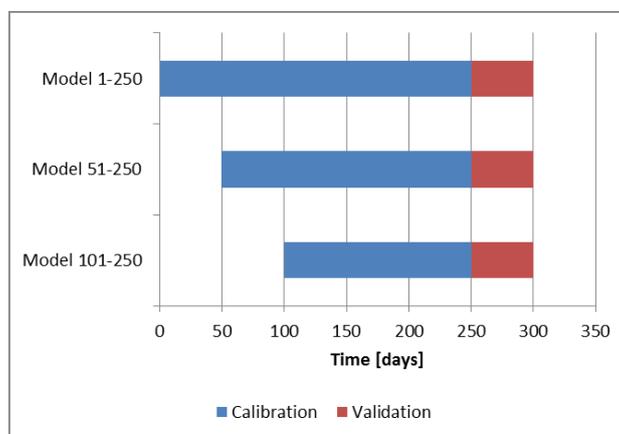
**Tab. I.5:** Valori delle metriche di errore MPE e CVE, calcolati nella fase di calibrazione e di validazione, per differenti numerosità dei dati di calibrazione.

	Numerosità dei dati di calibrazione		
	150	200	250
MPE (calibrazione)	-0.00697	-0.01818	-0.02172
MPE (validazione)	0.43773	-0.03565	-0.02035
CVE (calibrazione)	0.004097	0.005047	0.006159
CVE (validazione)	0.008246	0.009509	0.005691

Infine le metriche di errore MPE e CVE definite nelle formule I.9 e I.10, sono state calcolate per i tre scenari descritti in precedenza e i risultati sono mostrati nella tabella I.5.

### *1.1.5 Calibrazione su di un set di dati crescente verso il passato e validazione sugli stessi 50 dati osservati*

Al fine di verificare le capacità del modello di predire dati futuri, si è attuata la calibrazione, estendendo il set di dati, in tre diversi intervalli di tempo: partendo dal 101° giorno al 250° (150 periodi), poi dal 51° al 250° giorno (200 periodi) ed infine considerando disponibili tutti i dati prima della validazione, che è effettuata sempre dal 251° giorno al 300° (50 periodi). L'intervallo di calibrazione variabile e quello fisso di validazione sono riportati nella figura I.11. I parametri del modello stimati usando i tre set di dati sono riportati nella tabella I.6.



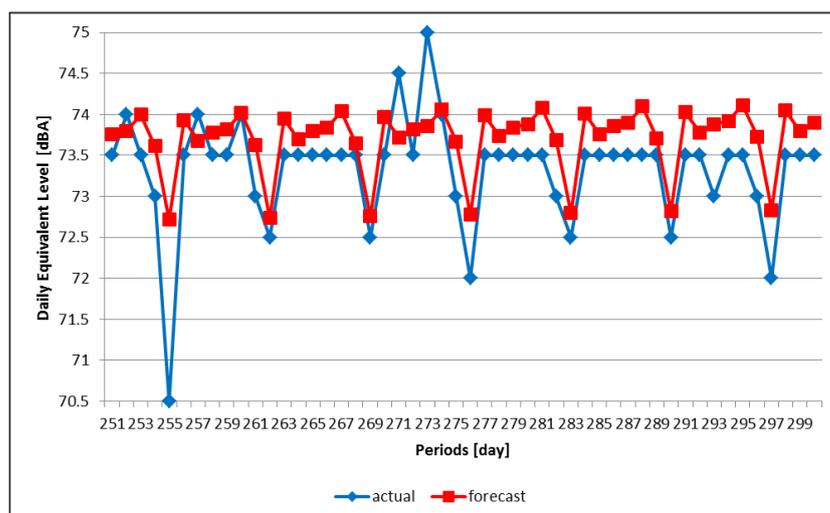
**Fig. I.11:** Numerosità crescente dei dati di calibrazione e intervallo di validazione fisso.

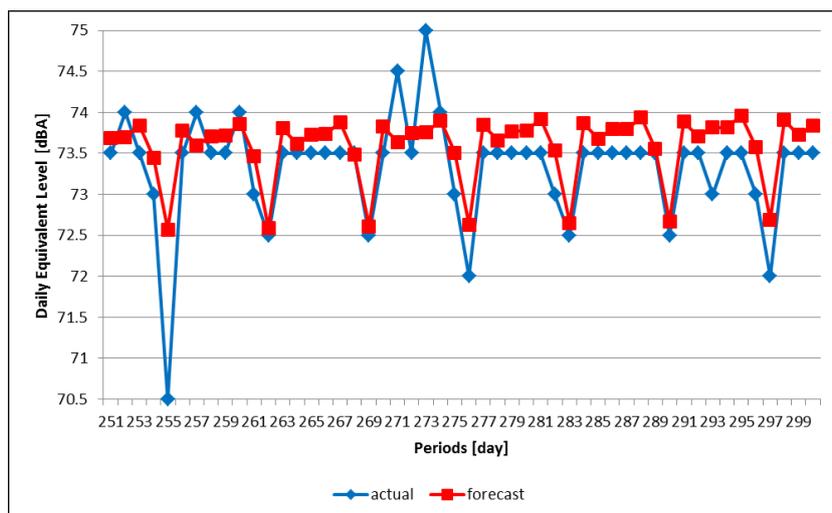
**Tab. I.6:** Parametri stimati del modello usando i tre diversi intervalli di calibrazione.

	Intervallo di calibrazione [giorni]		
	101-250	51-250	1-250
$b_1$	0.002804236	0.00295778	0.00205197
$b_0$	72.93012543	72.763531	72.7738095
$\bar{S}_1$ lunedì	1.00380	1.00354	1.00321
$\bar{S}_2$ martedì	1.00038	1.00101	1.00184
$\bar{S}_3$ mercoledì	1.00171	1.00248	1.00243
$\bar{S}_4$ giovedì	1.00224	1.00248	1.00280
$\bar{S}_5$ venerdì	1.00484	1.00443	1.00514
$\bar{S}_6$ sabato	0.99957	0.99908	0.99826
$\bar{S}_7$ domenica	0.98741	0.98707	0.98625

Esaminando i coefficienti del modello è possibile ottenere molte informazioni riguardo l'andamento degli agenti inquinanti studiati. Nel caso analizzato i livelli di rumorosità nell'area soggetta alle misure non mostra variazioni rilevanti nel trend: il coefficiente  $b_1$  della linea di regressione è vicino allo zero. Dunque il coefficiente  $b_0$  può essere assimilato al valor medio del livello di rumore nel sostanzialmente breve periodo di tempo analizzato. Questo genere di inquinante sembra avere una risposta rapida legata alle attività umane: i coefficienti di stagionalità sono minori di uno il sabato e la domenica, cioè durante il fine settimana, nel quale c'è una riduzione delle sorgenti di rumorosità come il flusso di traffico e le attività del porto commerciale vicino alla stazione di monitoraggio.

Il risultato della previsione nei tre scenari è visibile nelle figure I.12, I.13 e I.8. Si ricorda che l'ultimo scenario che prevede la calibrazione sull'intervallo di dati dal 1° periodo al 250° e la validazione sugli ultimi 50 giorni (dal 251° al 300°), è analogo al caso mostrato nel paragrafo precedente 1.1.4.

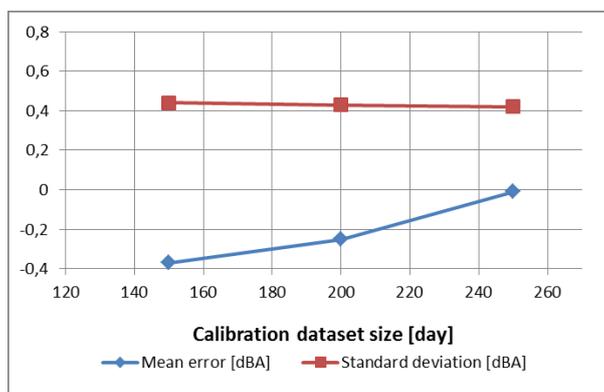
**Fig. I.12:** Confronto tra le previsioni, ottenute calibrando il modello con i dati dal 101° al 250°. La comparazione è sui 50 dati reali dal 251° al 300°.



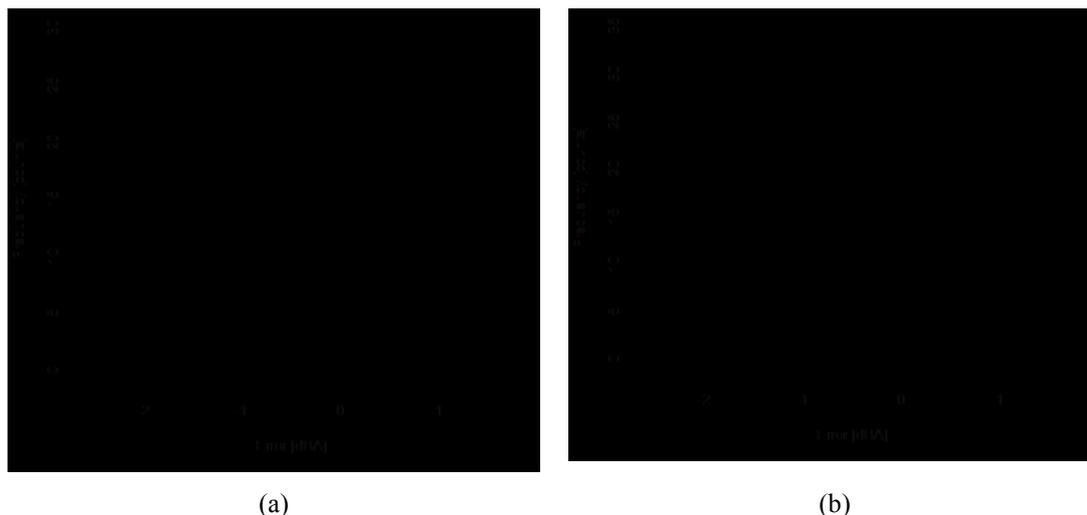
**Fig. I.13:** Confronto tra le previsioni, ottenute calibrando il modello con i dati dal 51° al 250°. La comparazione è sui 50 dati reali dal 251° al 300°.

**Tab. I.7:** Confronto tra le statistiche della distribuzione degli errori durante la fase di validazione in funzione dell'ampiezza del set di dati di calibrazione.

Intervallo di calibrazione	Media [dBA]	Dev.Std. [dBA]	Mediana [dBA]	Min [dBA]	Max [dBA]
101-250	-0.37	0.44	-0.37	-2.22	1.14
51-250	-0.25	0.43	-0.28	-2.07	1.25
1-250	-0.01	0.42	-0.04	-1.79	1.46



**Fig. I.14:** Media e deviazione standard della distribuzione degli errori ottenute validando il modello sugli stessi 50 dati reali, in funzione della numerosità dei dati di calibrazione aumentati verso il passato.



**Fig. I.15:** (a) Istogramma di frequenza degli errori calcolati durante la validazione del modello ottenuti calibrando con i dati dal 101° al 250°. (b) Istogramma di frequenza degli errori calcolati durante la validazione del modello ottenuti calibrando con i dati dal 51° al 250°.

**Tab.I.8:** Valori delle metriche di errore MPE e CVE, calcolati nella fase di calibrazione e di validazione, per differenti numerosità dei dati di calibrazione.

	Intervallo di calibrazione [giorni]		
	101-250	51-250	1-250
MPE (calibrazione)	-0.4164	-0.22847	-0.02172
MPE (validazione)	-0.51539	-0.34955	-0.02035
CVE (calibrazione)	0.008159	0.006848	0.006159
CVE (validazione)	0.007955	0.006866	0.005691

Osservando le previsioni nelle figure I.12, I.13 e I.8 è evidente che il modello presentato fornisce le migliori prestazioni incrementando la numerosità dei dati di calibrazione. Questo è dovuto al fatto che l'andamento dei livelli di rumore non varia drasticamente nel set di dati di calibrazione, sia in termini di trend che di periodicità. Questo risultato è confermato dall'analisi degli errori riportata nella tabella I.7: la media e la deviazione standard dell'errore decrescono, in valore assoluto, se c'è la possibilità di calibrare i parametri del modello su di un set di dati più ampio (Fig. I.14).

Gli istogrammi di frequenza dell'errore relative alla fase di validazione (eseguita sui dati dal 251° al 300°), riportati nella figura I.15, mostrano che l'assunzione di distribuzione normale degli errori è ragionevole.

Le prestazioni del modello, valutate in accordo con le metriche di errore descritte nel paragrafo 1.1.1., sono mostrate nella tabella I.8. La dispersione dell'errore, evidenziata dal CVE, decresce in maniera costante facendo crescere la numerosità dei dati di calibrazione. L'MPE si riduce leggermente (in valore assoluto) nel secondo scenario, cioè aggiungendo 50 dati alla calibrazione. Nel terzo scenario, aggiungendo 100 dati, l'MPE si avvicina drasticamente allo zero. Questo risultato è ottenuto perché i dati inseriti nell'ultimo scenario di calibrazione (dall'1° al 50° periodo) hanno un andamento molto simile ai dati del periodo di validazione.

### 1.1.6 Discussione sui risultati ottenuti

In questo paragrafo è stato presentato un modello di decomposizione deterministico basato sull'analisi di una serie storica (TSA); è stato previsto un metodo misto, moltiplicativo tra trend e stagionalità e additive per la componente di errore (irregolarità della serie). È stata inoltre presentata l'applicazione di tale modello ad un set di dati di rumorosità acustica.

I dati analizzati presentano un andamento (trend) quasi stazionario, evidenziato da una retta di regressione leggermente crescente. Il modello, calibrato sui primi 150 periodi, fornisce una buona previsione dei successivi 171 dati, con un errore medio di 0.33 dBA e una deviazione standard dell'errore di 0.52 dBA. Inoltre la forma dell'istogramma degli errori e gli indici di curtosi e asimmetria, confermano l'ipotesi di distribuzione normale per questi errori di previsione.

È stata eseguita e presentata un'analisi delle prestazioni del modello al variare della numerosità dei dati di calibrazione. Un miglioramento delle statistiche degli errori era attesa ed è stata confermata utilizzando la più ampia numerosità di periodi di calibrazione. Tuttavia la crescita della dispersione intorno alla media dei valori reali nel secondo intervallo di validazione, evidenziata dal crescere della deviazione standard dei dati, ha causato una degradazione delle prestazioni previsionali del modello in questo secondo passaggio. Come atteso, il *Mean Percentage Error* (MPE) calcolato sui dati di validazione diminuisce al crescere della numerosità dei dati di calibrazione. La dispersione dell'errore (misurata con il CVE) cresce leggermente quando il modello è calibrato su 200 dati invece che su 150 a causa della crescita della variabilità dei dati descritta prima, ma si riduce significativamente quando, nell'ultimo passaggio, la calibrazione viene effettuata su 250 periodi.

Inoltre è stata svolta una calibrazione del modello su tre diversi intervalli di tempo, ampliando il set di calibrazione verso il passato, effettuando una validazione sempre sugli stessi 50 dati. L'ultima applicazione conferma il miglioramento delle capacità previsionali del modello TSA alla crescita dell'intervallo di calibrazione. Questo risultato, supportato dalle statistiche di distribuzione dell'errore e dai valori delle metriche di errore, può essere spiegato considerando che l'andamento dei livelli di rumore non presenta drastici cambiamenti con il passare del tempo, sia in termini di trend che di periodicità.

In fine, il modello proposto ha mostrato buone prestazioni previsionali, risultando allo stesso tempo facile da essere implementato e con un carico computazionale basso. Può essere implementato ed eseguito in computer di basse prestazioni e in piattaforme informatiche portatili, dando l'opportunità di essere utilizzato in stazioni di monitoraggio e previsione installate sul posto di interesse, consentendo la capacità di trasmettere i dati misurati ma anche i valori previsti per gli intervalli di tempo futuri. Per queste applicazioni la prima analisi presentata con la variazione della numerosità dei dati di calibrazione può aiutare gli operatori a capire quando il modello comincerà a fornire previsioni affidabili, a partire dalla data di installazione e messa in opera, e quale intervallo è più opportuno usare nella fase di calibrazione. La seconda analisi sul set di calibrazione variabile, può essere utile per capire quanti dati del passato devono essere presi in considerazione per avere la migliore previsione su un dato intervallo futuro.

## 1.2 Analisi e previsione di rumore acustico con l'utilizzo di un modello a stagionalità multipla

La popolazione residente in grandi agglomerati urbani vede la propria salute spesso minacciata da varie forme di inquinamento: prodotti della combustione, intensi campi elettromagnetici, rumorosità ambientale elevata [18-19]. Il monitoraggio costante di questi inquinanti è generalmente costoso e non sempre facile da essere implementato. Inoltre azioni di mitigazione sulle sorgenti sono spesso consequenziali a periodi nei quali il livello di inquinamento è stato particolarmente alto e dunque ha già messo in pericolo la salute dei cittadini. Queste considerazioni fanno emergere la necessità di implementare modelli previsionali che possano fornire affidabili previsioni dei livelli di inquinamento (vedere ad esempio [20,21]). Questi modelli possono suggerire possibili misure di mitigazione, agendo anche sulle sorgenti, prima che l'inquinamento cominci a minacciare la popolazione.

In questo paragrafo viene affrontato il problema della previsione del livello di rumorosità acustica nelle aree urbane. Tale rumorosità è principalmente generata dalle attività antropiche, in particolare dal traffico veicolare e da altre infrastrutture di trasporto.

La maggior parte dei modelli previsionali esistenti usati per stimare i livelli di inquinamento sono basati sullo studio di correlazione e degli effetti casuali che derivano dalle sorgenti. A causa della natura fisica del fenomeno nel caso della rumorosità Acustica, è molto difficile prevedere gli effetti in un'area limitata studiando solo le sorgenti. Infatti il campo acustico può essere fortemente influenzato sia dall'architettura dell'area nella quale sono state prese le misure, sia da altre interferenze ambientali fortemente variabili nel tempo.

Il modello previsionale considerato è basato sull'analisi delle serie storiche (TSA) [22,23], applicato a misurazioni di livello sonoro. Il modello può prevedere l'evoluzione dei livelli di rumorosità per un certo intervallo di tempo, in una specifica area di interesse, cioè l'area nella quale i dati usati per la stima di parametri e coefficienti del modello (fase di calibrazione) sono stati raccolti. La funzione di previsione usata è nota nella sua forma generale ma deve essere adattata agli specifici dati analizzati per avere valori di previsione più accurati. In particolare, la forma funzionale più semplice del modello può essere usata con successo quando sono disponibili poche misurazioni per la stima dei parametri. Se è disponibile un set di dati di calibrazione più ampio è possibile implementare modelli più complessi per ridurre l'errore di previsione.

In particolare in questo studio è stato usato un set di misurazioni della rumorosità registrata durante la notte nella città di Messina.

Questi dati sono costituiti dal livello di pressione Sonora equivalente ( $L_{A,eq}$ ), mediato sulle otto ore notturne (dalle 22:00 alle 6:00), definito dalla formula seguente:

$$L_{Aeq,Te} = 10 \log \left[ \frac{1}{\sum t_i} \sum_{i=1}^n \left( 10^{\frac{L_{Aeq,i}}{10}} t_i \right) \right], \quad (I.13)$$

nella quale  $T_e$  è il tempo di esposizione (dalle 22:00 alle 6:00),  $t_i$  è il singolo periodo della serie, cioè il singolo giorno,  $L_{A,eq,i}$  è il livello equivalente misurato nel periodo  $i$ -esimo. L'indice "A" segnala che la curva di ponderazione  $A$  è stata applicata ai dati, come richiesto dalla regolamentazione europea [24].

Il primo passo consiste nel costruire un semplice ma utile modello che lavora sulle prime 321 misurazioni disponibili. Successivamente, con questo modello, sono stati inseriti 26 dati mancanti, consecutivi tra loro, con i valori previsti.

Questo è stato fatto con lo scopo di avere una estesa serie storica senza dati mancanti. La nuova serie di 500 dati può essere usata per elaborare un modello più sofisticato. Infine, per validare il modello, un confronto tra i dati reali e quelli previsti è stato effettuato sulle ultime 44 misurazioni disponibili. Naturalmente le 44 misurazioni usate per la validazione non sono state usate per la stima dei parametri e dei coefficienti.

### 1.2.1 Struttura matematica di un modello a stagionalità multipla

La procedura usata per costruire il modello si basa sulle assunzioni generali di modelli di decomposizione deterministici tipiche dell'analisi TSA.

Tali modelli riproducono l'andamento in funzione del tempo di una certa serie storica e possono essere usati per prevedere i dati in un intervallo di tempo futuro. L'orizzonte di previsione dipende dall'affidabilità del modello e dalla variabilità della serie.

L'assunzione principale del modello usato prevede che la serie osservata,  $Y_t$ ,  $t \geq 0$ , può essere fornita da una funzione del tipo:

$$Y_t = \hat{Y}_t + e_t, \quad (I.14)$$

dunque  $\hat{Y}_t$  rappresenta il valore previsto ad un certo tempo  $t$ , e  $e_t$  è la componente casuale.

In questa applicazione è stato utilizzato un metodo moltiplicativo, in accordo alla formula I.4:  $\hat{Y}_t = T_t \bar{S}_i$ , nella quale  $\hat{Y}_t$  è la previsione puntuale,  $T_t$  è il trend e  $\bar{S}_i$  è il coefficiente stagionale.

La componente di trend può essere valutata mediante tecniche di regressione, utilizzando in particolare una regressione lineare sui dati reali, o dopo aver rimosso la stagionalità con il metodo della media mobile. In questa applicazione si è scelto di calcolare il trend con una regressione lineare sui dati reali. L'ampiezza dell'intervallo sul quale è calcolata la media mobile centrata dipende dalla periodicità riscontrata nei dati ed è anche chiamata "ritardo". Questo ritardo (in inglese *lag*) è fortemente legato al fenomeno studiato e alle sue caratteristiche. In alcuni casi può essere riscontrata anche una periodicità multipla.

Nel prosieguo verrà mostrato come un modello TSA migliora quando un ritardo multiplo è riscontrato e implementato per calcolare i valori previsti.

Il coefficiente di stagionalità è calcolato come media, ricavata su tutti i periodi analoghi, del rapporto tra il valore reale e la media mobile centrata in un periodo  $t$ .

Se è stata riscontrata più di una periodicità, la previsione è corretta con un altro coefficiente di stagionalità:

$$\hat{Y}_t = T_t \bar{S}_{1,i} \bar{S}_{2,j}, \quad (I.15)$$

nella quale  $\bar{S}_{1,i}$  e  $\bar{S}_{2,j}$  sono i due diversi coefficienti di stagionalità.

Allo scopo di rimuovere gli effetti della stagionalità di breve periodo, una media mobile centrata di ampiezza  $k_1$  (primo ritardo riscontrato) può essere usata. E' dunque possibile riscontrare l'effetto ricorrente sul singolo giorno mediante il rapporto tra dato reale al periodo  $t$  e la media mobile centrata allo stesso periodo  $t$ . Infine, valutando la media di questo effetto  $S_{1,t}$  sugli  $m_{1,i}$  periodi omologhi, il coefficiente stagionale  $\bar{S}_{1,i}$  è ottenuto:

$$S_{1,t} = \frac{Y_t}{M_{(k_1)t}}, \quad (I.16)$$

si ha dunque:

$$\bar{S}_{1,i} = \frac{\sum_{l=0}^{m_{1,i}-1} S_{1,i+l k_1}}{m_{1,i}}, \quad (\text{I.17})$$

nella quale  $M_{(k_1)t}$  è la media mobile centrata di ampiezza  $k_1$ , al periodo  $t$ .

A questo punto è possibile rimuovere dai valori della prima media mobile l'effetto della seconda stagionalità con ritardo  $k_2$ . Questo è ottenuto usando un secondo processo di media mobile centrata con ampiezza  $k_2$ . Come al passaggio precedente l'effetto della seconda stagionalità per ogni periodo ( $S_{2,t}$ ) può essere calcolato, e un secondo coefficiente di stagionalità può essere valutato con una media sugli  $m_{2,j}$  periodi omologhi:

$$S_{2,t} = \frac{M_{(k_1)t}}{M_{(k_2)t}}, \quad (\text{I.18})$$

$$\bar{S}_{2,j} = \frac{\sum_{l=0}^{m_{2,j}-1} S_{2,j+l k_2}}{m_{2,j}}, \quad (\text{I.19})$$

nella quale  $M_{(k_2)t}$  è la media mobile centrata di ampiezza  $k_2$ , al periodo  $t$ .

Avendo assunto la presenza di una componente irregolare indicate da  $e_t$ , questa è calcolata in accordo alla formula I.8. l'errore è causato da una componente non deterministica del fenomeno fisico studiato che il modello non riesce a prevedere. Questa procedura è attuabile quando il dato reale è disponibile, tipicamente nella fase di calibrazione. Quando si è ottenuta la distribuzione dell'errore, la sua media ( $m_e$ ) può essere usata nella previsione finale e la deviazione standard può essere collegata alla larghezza di un intervallo di previsione. Dunque la previsione puntuale può essere migliorata come segue:

$$\hat{Y}_t = T_t \bar{S}_{1,i} \bar{S}_{2,j} + m_e. \quad (\text{I.20})$$

Un processo di validazione può essere svolto confrontando i dati reali con i valori previsti dal modello in un intervallo di tempo non usato nella fase di calibrazione.

Per valutare l'efficacia del modello è utile implementare un'analisi statistica degli errori. Questa metodologia è applicata sia nella fase di calibrazione che in quella di validazione.

Un obiettivo importante per l'ottimizzazione del modello è quello di minimizzare sia il valore assoluto della media che quello della deviazione standard della distribuzione dell'errore di previsione.

Al fine di riscontrare la presenza di una periodicità nella serie, il primo passo è l'adozione dei test statistici di Ljung-Box (LB) e Box-Pierce (BP) ([25], [26]). Questi test verificano la presenza di una possibile autocorrelazione nei dati ed escludono la fluttuazione puramente casuale dei dati. Entrambi i test adottano il coefficiente di autocorrelazione che può essere valutato in accordo alla seguente formula:

$$r(k) = \frac{\sum_{t=1}^{n-k} (y_t - \bar{y})(y_{t+k} - \bar{y})}{\sum_{t=1}^n (y_t - \bar{y})^2}, \quad (\text{I.21})$$

nella quale  $y_t$  è il dato in ogni periodo  $t$ ,  $\bar{y}$  è la media di tutti i dati,  $n$  è il numero totale di periodi,  $k$  è l'ipotesi di ritardo sotto test. Usando questo coefficiente il test LB può essere usato in accordo alla formula seguente:

$$\chi_{LB}^2(h) = n(n+2) \sum_{k=1}^h \frac{r^2(k)}{n-k}, \quad (I.22)$$

nella quale  $h$  è un intero scelto in relazione al numero di coefficiente di autocorrelazione da testare e varia in funzione del ritardo ipotizzato.

Se l'ipotesi nulla è vera (assenza di autocorrelazione), la statistica LB è distribuita come una variabile casuale  $\chi^2$  con  $h$  gradi di libertà.

Invece il test BP è basato sulla formula seguente:

$$\chi_{BP}^2(h) = n \sum_{k=1}^h r^2(k), \quad (I.23)$$

nella quale, ancora,  $n$  è il numero totale di periodi,  $k$  è il ritardo e  $h$  è un intero scelto in relazione al numero di coefficienti di autocorrelazione da testare. I due test differiscono solo per il sistema di pesatura adottato, ma convergono asintoticamente alla stessa distribuzione.

Quando i test confermano la presenza di una periodicità nei dati, la scelta del ritardo opportuno può essere effettuata mediante la massimizzazione del coefficiente di autocorrelazione. Uno strumento molto utile per rilevare la giusta periodicità e per valutare l'autocorrelazione in funzione del ritardo, è il grafico dell'autocorrelazione, chiamato anche correlogramma. Questo grafico riporta sulle ascisse il valore di  $k$  e sulle ordinate il corrispondente valore del coefficiente di autocorrelazione. In questo capitolo, dato che i correlogrammi sono stati realizzati nell'ambiente software di "R" il coefficiente di autocorrelazione è calcolato in accordo con la formula I.21.

La formula I.21 adotta al denominatore un'unica media calcolata sull'intero intervallo dei dati. Può essere utile tuttavia, quando la serie di dati non presenta un andamento della media sufficientemente costante (ad esempio quando si riscontra una retta del trend con elevato coefficiente angolare), adottare la formula I.1. Nella formula I.2 le due medie al denominatore sono calcolate escludendo rispettivamente i primi e gli ultimi  $k$  periodi.

Inoltre, quando il ritardo è particolarmente ampio (sta alla sensibilità dell'analista dati giudicare l'ampiezza del ritardo considerato ai fini della più opportuna metodologia per il calcolo dell'autocorrelazione), un altro possibile metodo è quello di valutare il coefficiente di correlazione tra un sottoinsieme del set di dati e lo stesso set di dati traslato di  $k$  periodi:

$$r_{xy} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{(\sum_{i=1}^n (x_i - \bar{x})^2)^{\frac{1}{2}} (\sum_{i=1}^n (y_i - \bar{y})^2)^{\frac{1}{2}}}, \quad (I.24)$$

nel quale where  $x_i$  is equal to  $y_i - k$ .

Per quanto riguarda l'analisi degli errori, è utile verificare che la media dei residui (errori) non sia statisticamente diversa da zero. In questo paragrafo viene utilizzato il  $t$ -test:

$$t = \frac{\bar{e}}{s/\sqrt{n}}, \quad (\text{I.25})$$

nella quale  $\bar{e}$  è la media dell'errore,  $s$  è la deviazione standard e  $n$  è la numerosità dei dati.

L'ipotesi nulla da verificare  $H_0$  è "media zero dell'errore". Dunque al numeratore dell'equazione I.25 c'è solo la media empirica (solitamente vi si trova la media empirica meno quella ipotizzata). In questo tipo di test statistici è possibile avere due tipologie di errore. Il primo è il rifiuto dell'ipotesi nulla  $H_0$  quando questa è vera (che può accadere con probabilità  $\alpha$ , che è il livello di significatività). Il secondo tipo di errore è accettare  $H_0$  quando è falsa (questo può accadere con probabilità  $\beta$ , e  $1 - \beta$  è la potenza del test).

E' altresì importante valutare se gli errori di previsione sono casuali e dunque ottenibili da una distribuzione normale. Per accertare la normalità della distribuzione degli errori vengono utilizzati sia metodi qualitativi basati sull'analisi di grafici come istogrammi, diagrammi quantile-quantile, sia indici quantitativi tipo asimmetria e curtosi. Il grafico di densità normale [27] è una tecnica grafica per valutare se una serie di dati è approssimativamente distribuita secondo una normale. I dati sono diagrammati in raffronto ad una distribuzione normale ipotetica in maniera che i punti dovrebbero formare una linea retta. Deviazioni da questa linea retta indicano deviazioni dalla normalità.

Inoltre vengono adottati i test statistici di normalità Shapiro-Wilk [28] e Jarque-Bera [29]. Il test di Shapiro-Wilk (SW) è capace di verificare la normalità di un set di dati fornendo buoni risultati anche per un piccolo numero di osservazioni. La formula usata è:

$$SW = \frac{(a'x)^2}{\sum_{i=1}^n (x_i - \bar{x})^2} = \frac{(\sum_{i=1}^n a_i x_i)^2}{\sum_{i=1}^n (x_i - \bar{x})^2}, \quad (\text{I.26})$$

con:

$$a' = (a_1, \dots, a_n) = \frac{m'V^{-1}}{(m'V^{-1}V^{-1}m)^{1/2}}, \quad (\text{I.27})$$

nella quale  $m' = (m_1, m_2, \dots, m_n)$  indica il vettore dei valori attesi della statistica d'ordine normale standardizzata, e  $V = (v_{ij})$  è la corrispondente  $n \times n$  matrice di varianza-covarianza, e  $x' = (x_1, x_2, \dots, x_n)$  indica un vettore di osservazioni casuali ordinate.

Il test di Jarque-Bera (JB) è spesso usato per verificare l'ipotesi di normalità nell'area econometrica. È basato sulle misure di asimmetria e curtosi della distribuzione. L'ipotesi nulla del test include due condizioni: l'asimmetria e l'eccesso di curtosi devono essere zero (ovvero la curtosi deve essere 3). Se questa ipotesi è verificata, i dati possono essere considerati derivare da una distribuzione normale, e la statistica JB tende ad una distribuzione chi-quadro con due gradi di libertà. Il test JB è in generale meno robusto nell'applicazione a piccoli campioni, rischiando di rigettare spesso l'ipotesi nulla erroneamente. Il test è basato sulla seguente espressione.

$$JB = \frac{n}{6} \left( \frac{m_3}{m_2^{3/2}} \right)^2 + \frac{n}{24} \left( \left( \frac{m_4}{m_2^2} \right) - 3 \right)^2, \quad (\text{I.28})$$

nella quale  $m_k = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^k$ , con  $k = 2, 3, 4$ .

### 1.2.2 Analisi dei dati: Viale Bocchetta notte

Il set di misurazioni usato in questo paragrafo è stato estratto dai dati raccolti nella città di Messina, set di misurazioni fonometriche descritto precedentemente. In particolare, nel paragrafo precedente sono state usate le misure acquisite a Viale Bocchetta durante il giorno. In questo paragrafo, sono analizzate le misure notturne raccolte nello stesso sito, e parzialmente negli stessi mesi. In particolare sono stati scelti 4 set di dati: il primo corrisponde a un intervallo temporale che va dall' 11 maggio 2007 al 26 marzo 2008 (321 giorni); il secondo intervallo va dal 27 marzo 2008 al 21 aprile 2008 (26 giorni nei quali le misure non sono state acquisite). Il terzo intervallo va dal 22 aprile 2008 al 21 settembre 2008 (153 giorni). Infine il quarto intervallo di dati, usato nella fase di validazione del modello, va dal 22 settembre al 4 novembre 2008 (44 giorni). Il livello notturno considerato è il livello equivalente, ponderato con curva  $A$ , valutato nell'intervallo di tempo  $T$ , che va dalle 22:00 alle 6:00 (8 ore), rispettando la formula I.11. Il primo obiettivo è stato usare un modello previsionale, calibrato sui 321 dati disponibili, per calcolare i 26 dati mancanti del secondo set di dati definito prima. Dopo aver ricostruito i dati mancanti della serie con le previsioni ottenute dalla prima decomposizione deterministica a singola stagionalità, metodologia descritta in precedenza, lo stesso modello è stato calibrato su un intervallo di 500 notti, composto dalle prime 321 misure, più le 26 ricostruzioni, più le successive 153 misurazioni. Inoltre, gli ultimi 44 dati (dal 501° al 544° periodo) sono stati lasciati per la validazione del modello. La scelta di questo ampio set di dati consente l'implementazione di un modello moltiplicativo con un doppio coefficiente di stagionalità che può riprodurre, in congiunzione con la stagionalità ( $k_1 = 7$ ), una seconda periodicità di lungo termine ( $k_2 = 125$ ). Nella seguente tabella I.9 sono fornite le principali statistiche del primo set di 321 misurazioni.

**Tab. I.9:** Statistiche riassuntive dei primi 321 periodi del set di dati disponibile.

Media [dBA]	Dev.Std [dBA]	Mediana [dBA]	Min [dBA]	Max [dBA]
68.77	1.19	69.0	66.0	72.0

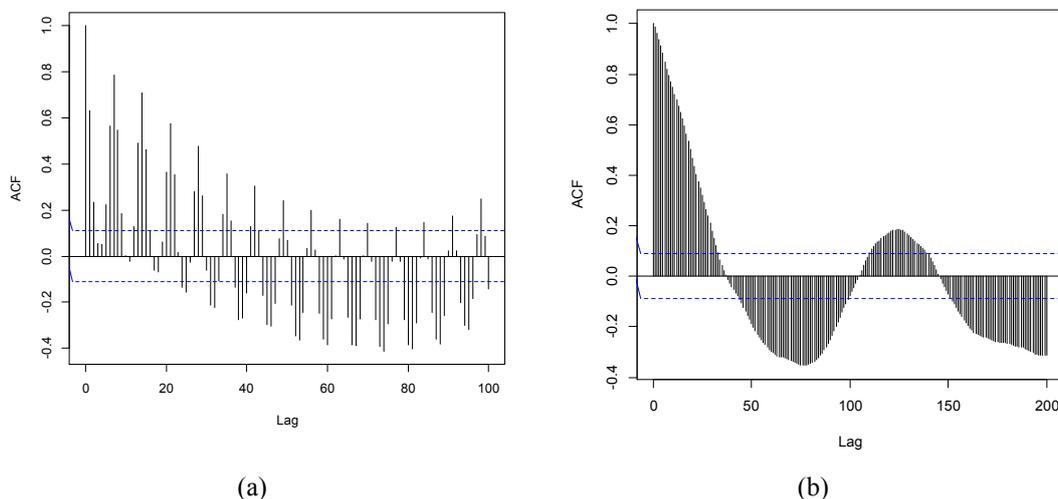
Al fine di valutare la presenza di una periodicità, il primo passo è stato applicare i test di Ljung-Box (LB) e Box-Pierce (BP), definiti in precedenza. Questi test evidenziano la presenza di autocorrelazione nei dati. I test sono stati implementati nell'ambiente di lavoro del programma di elaborazione statistica "R" e i risultati sono forniti nella tabella I.10.

**Tab. I.10:** Test di Ljung-Box e Box-Pierce applicati alle prime 321 misure del set di dati disponibile.

Tipologia di test	$\chi^2$	$h$	$p$ -value
Ljung-Box	584.749	10	< 2.2e-16
Box-Pierce	1514.589	50	< 2.2e-16

Il basso  $p$ -value di entrambi i test, ossia la piccolissima probabilità di osservare il campione se l'ipotesi nulla è vera, indica che l'ipotesi di assenza di autocorrelazione nei dati deve essere rifiutata.

In un successivo passo, usando il correlogramma ricavato nel software "R", la periodicità è stata investigata nei primi 321 periodi. Questo correlogramma è riportato nella figura I.16(a).



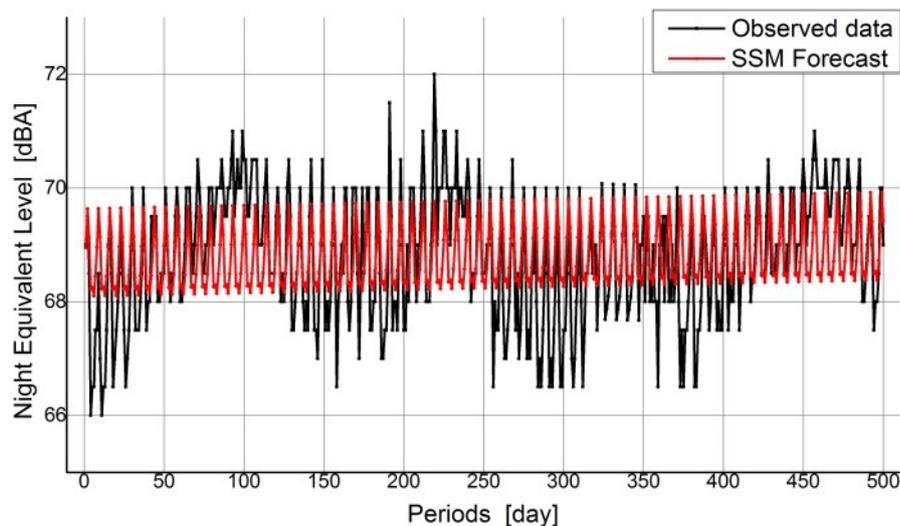
**Fig. I.16:** (a) Correlogramma dei primi 321 giorni. (b) Correlogramma dei valori della media mobile centrata. Il valore dell'autocorrelazione è diagrammato in funzione della periodicità considerata.

Il valore più alto del coefficiente di autocorrelazione si è ottenuto per un ritardo pari a 7 e il suo valore, calcolato mediante la formula I.21, è stato 0.79. È dunque evidente che vi è una periodicità settimanale nei dati di rumorosità. Questo risultato è ragionevole, poiché le misure sono fortemente correlate al flusso di traffico, tipicamente più alto durante i giorni lavorativi e minore durante i fine-settimana.

A questo punto un primo modello (modello a stagionalità singola SSM) usando la procedura descritta nella precedente sezione, è stato implementato considerando questo ritardo, ossia media mobile centrata e coefficiente di stagionalità in accordo con una periodicità pari a 7.

Questo modello consente di riempire l'intervallo mancante dal periodo 322 al 348, rendendo così disponibile un set di dati di 500 misure.

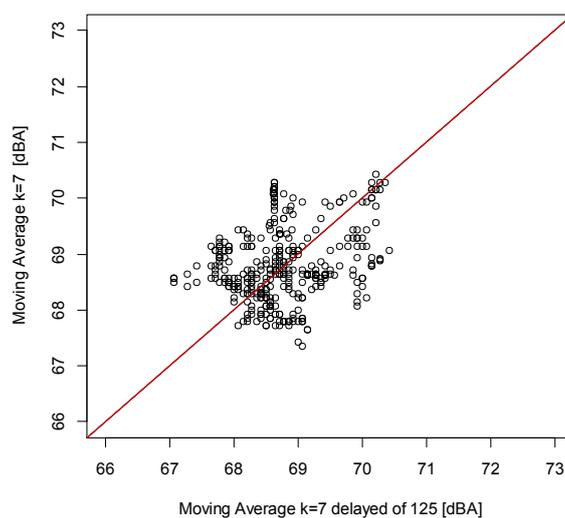
Nella figura I.17 è possibile vedere come il set di dati mancanti è stato ricostruito e come il modello approssima la serie storica misurata. Su questo set di dati più grande (500 giorni), una seconda stagionalità, con una frequenza più piccola della prima, è visibile e può essere sfruttata. L'autocorrelazione dei valori della media mobile centrata (con ritardo 7) è mostrata e può essere indagata nel correlogramma di figura I.16(b).



**Fig. I.17:** Confronto tra le previsioni, ottenute dal modello a singola stagionalità (SSM), e i 500 dati reali di calibrazione.

Il correlogramma evidenzia una autocorrelazione positiva statisticamente significativa per un ritardo pari a 125. Questo coefficiente di autocorrelazione è stato valutato in accordo con la formula I.1 fornendo un valore di 0.20. Il programma “R”, calcolando lo stesso coefficiente con la formula I.21, ha fornito un valore di 0.19. Anche la formula I.24 è stata utilizzata, quest’ultima ha il vantaggio di usare differenti medie a seconda dei due sottoinsiemi di dati divisi dal ritardo ipotizzato: il risultato ottenuto è stato 0.55. Tale valore è stato ottenuto mediante una correlazione tra i primi 50 periodi e quelli dell’intervallo tra il 125° e il 175°.

Nella figura I.18 è riportato il diagramma di auto-dispersione, considerando un ritardo di 125 periodi. L’addensamento di dati lungo la bisettrice sembra confermare la periodicità ipotizzata nei dati.



**Fig. I.18:** Grafico di autodispersione. La media mobile di ampiezza 7 è diagrammata in funzione della stessa media mobile considerando ogni dato traslato di 125 giorni.

### 1.2.3 Progettazione del modello a doppia stagionalità

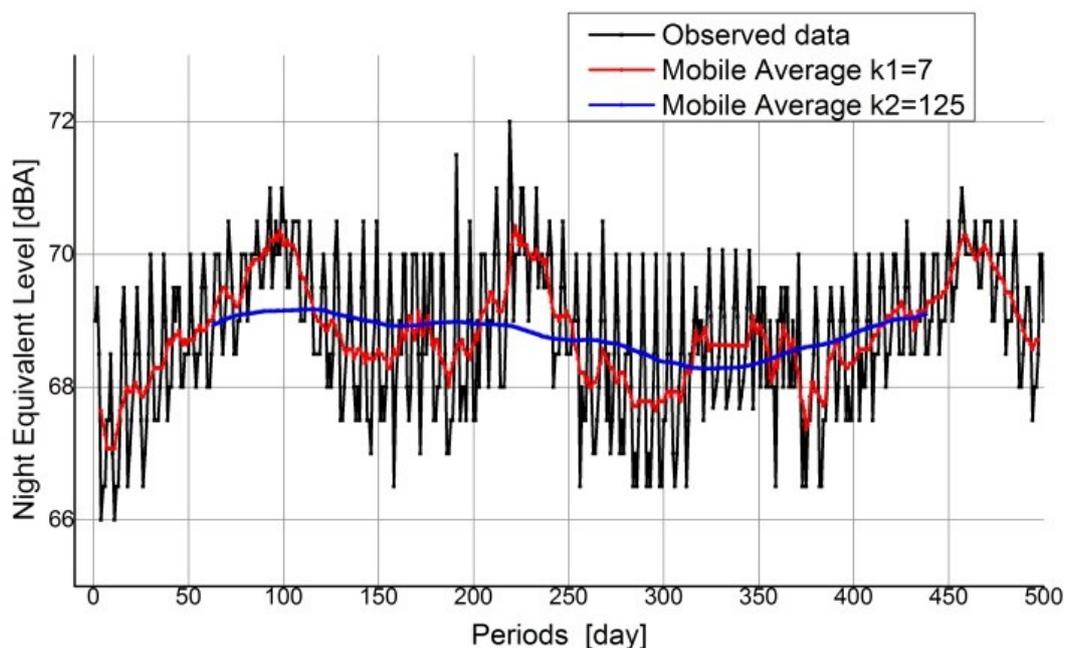
Dopo aver stabilito la presenza di due effetti stagionali, è possibile rimuovere queste periodicità nei dati e valutare due diversi coefficienti di stagionalità. Dunque, il modello migliorato tiene in conto gli effetti della stagionalità di alta frequenza, con un ritardo di 7 giorni, ma anche di quella a bassa frequenza, con un ritardo di 125 periodi. Nella figura I.19, sono riportate tre curve: i dati reali (in nero), in rosso la prima media mobile (ampiezza 7) e in blu la seconda media mobile (ampiezza 125).

In questa figura è possibile apprezzare la combinazione delle due medie mobili centrate, che eliminano l'effetto della doppia periodicità.

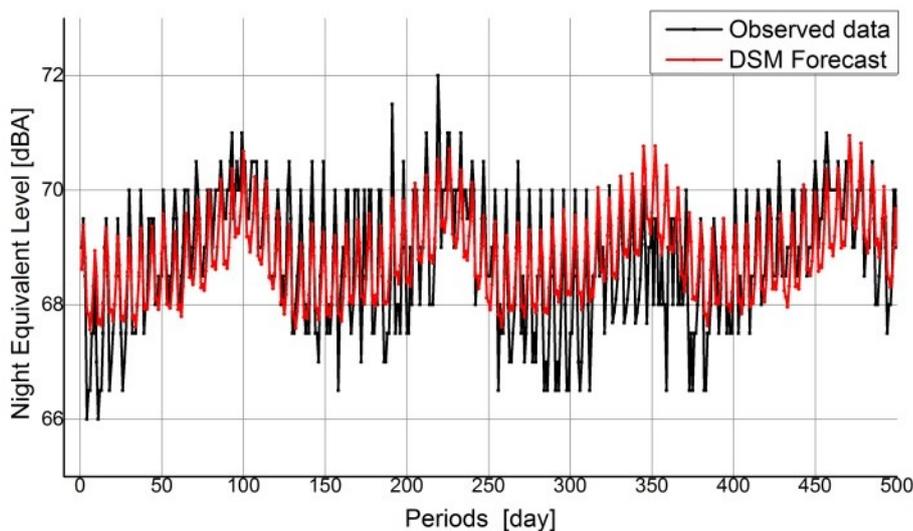
La curva rossa della prima media mobile mostra la presenza di quattro picchi e valli. Questa è una conferma empirica della presenza di una stagionalità di circa 500 misure su 4 picchi/valli, che è esattamente 125 periodi.

Nella figura I.20 è presentato un confronto tra i dati reali (linea nera) e i valori previsti dal modello a doppia stagionalità (DSM, linea rossa). Dal grafico è possibile apprezzare che i valori previsti riproducono bene quelli misurati.

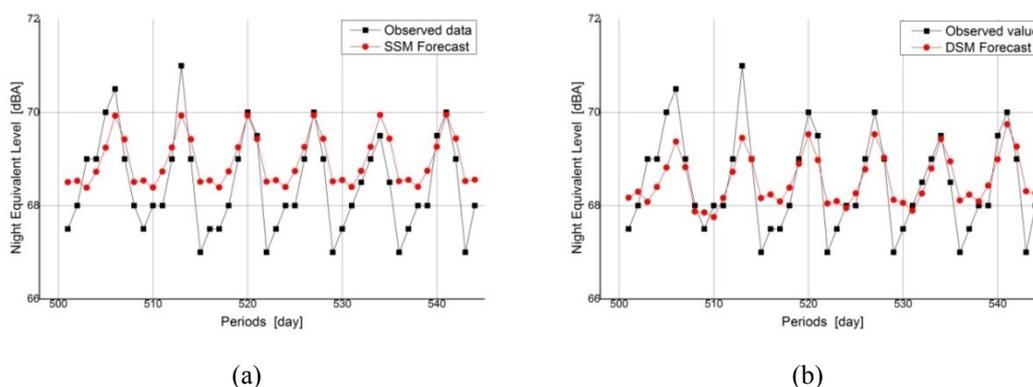
Sia il modello SSM che quello DSM sono stati validati su 44 periodi, ossia dalla  $501^\circ$  alla  $544^\circ$  misurazione. Un confronto grafico è stato effettuato nella figura I.21 (a) e (b), confrontando i dati reali con rispettivamente quelli previsti dal SSM e dal DSM. Una analisi quantitativa delle prestazioni dei due modelli è stata svolta calcolando le differenze tra i valori reali e quelli previsti dal SSM e dal DSM. Inoltre sono state misurate la distorsione e dispersione delle previsioni mediante i valori delle metriche del MPE e del CVE.



**Fig. I.19:** Grafico della combinazione delle due medie mobili. In nero i dati reali, in rosso la prima media mobile (di ampiezza 7), in blu la seconda media mobile (di ampiezza 125).



**Fig. I.20:** Confronto tra le previsioni, ottenute dal modello a doppia stagionalità (DSM), e i 500 dati reali di calibrazione.



**Fig. I.21:** (a) Confronto tra le previsioni, ottenute dal modello SSM, e la validazione con i dati reali. (b) Confronto tra le previsioni, ottenute dal modello DSM, e la validazione con i dati reali.

Le statistiche della distribuzione dell'errore, riportate in tabella I.11, mostrano un rilevante miglioramento delle previsioni del modello DSM rispetto al più semplice SSM. Il valore assoluto della media dell'errore decresce fortemente, anche se la deviazione standard è praticamente la stessa. Inoltre la distribuzione degli errori di previsione per il modello DSM approssima meglio una normale., considerando la diminuzione del modulo degli indici di asimmetria e curtosi.

I valori di MPE e CVE, riportati nella tabella I.12, confermano le migliori prestazioni del modello DSM. Le metriche di calibrazione dell'errore nella fase di calibrazione sono state calcolate escludendo i 26 periodi ricostruiti, ottenuti dall'applicazione del primo modello, e considerando solo i periodi per i quali era disponibile la misurazione.

Sia i confronti grafici che quelli quantitativi mostrano che il DSM ha prestazioni previsionali migliori, rispetto al modello con singola stagionalità, sul set di dati considerato.

**Tab. I.11:** Statistiche riassuntive della distribuzione degli errori per i modelli SSM e DSM stimate in fase di validazione.

Modello	Media [dBA]	Dev.Std [dBA]	Mediana [dBA]	Min [dBA]	Max [dBA]	skew	kurt
SSM	-0.49	0.62	-0.44	-1.53	1.07	0.29	-0.25
DSM	-0.07	0.64	-0.01	-1.31	1.55	0.21	-0.18

**Tab. I.12:** Valori delle metriche di errore MPE e CVE, calcolati nella fase di calibrazione e di validazione, per i due diversi modelli.

Tipologia di modello	Fase	MPE	CVE
SSM	calibrazione	0.0	0.013
SSM	validazione	-0.7	0.009
DSM	calibrazione	0.0	0.011
DSM	validazione	-0.1	0.012

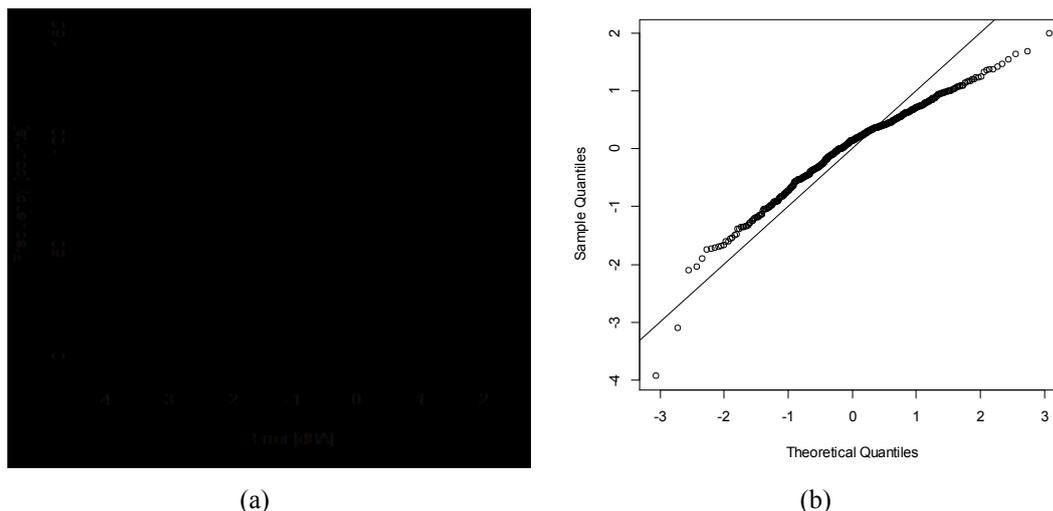
#### 1.2.4 Analisi dell'errore

Un'analisi statistica dell'errore di previsione è stata effettuata sui risultati del modello DSM, utilizzando i metodi presentati nei paragrafi precedenti.

Le statistiche riassuntive dell'errore di previsione del modello a doppia stagionalità sono riportate in tabella I.13. Gli errori sono quelli calcolati sui 474 dati di calibrazione, ossia sono stati esclusi le 26 misurazioni mancanti. L'istogramma di frequenza è mostrato in figura I.22(a).

**Tab. I.13:** Statistiche riassuntive della distribuzione degli errori stimate per l'intervallo di calibrazione.

Media [dBA]	Dev.Std. [dBA]	Mediana [dBA]	Min [dBA]	Max [dBA]	skew	kurt
0.02	0.74	0.15	-3.93	1.99	-0.79	1.72



**Fig. I.22:** (a) Istogramma di frequenza degli errori calcolati per i 474 dati di calibrazione. (b) Grafico quantile-quantile (distribuzione normale ipotizzata) che descrive l'andamento degli errori del modello DSM applicato ai 474 dati di calibrazione.

Calcolando il  $t$ -test nell'ambiente di programmazione di "R", si è potuto concludere che l'errore medio non è statisticamente diverso da zero. In particolare, la statistica  $t$  calcolata sugli errori del modello DSM, sui 474 periodi di calibrazione, è 0.6960518 e la probabilità corrispondente di osservare questi errori, se l'ipotesi nulla di media pari a zero fosse stata vera, è risultata di 0.2433691. Questo valore è solitamente considerato troppo alto per rigettare l'ipotesi nulla.

I risultati dei test di Shapiro-Wilk e Jarque-Bera sono riportati nella tabella I.14, mentre il diagramma quantile-quantile è presentato nella figura I.22(b).

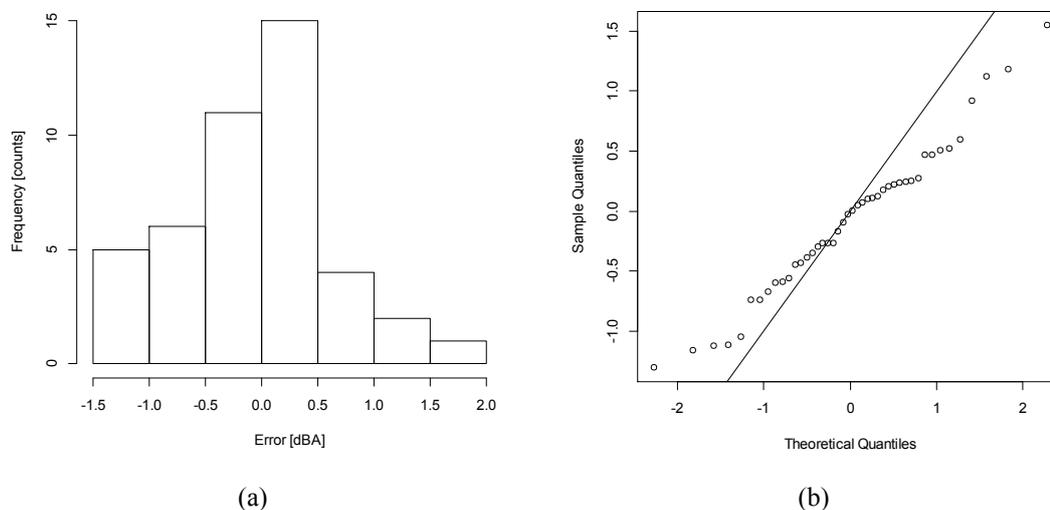
**Tab. I.14:** Test di normalità Shapiro-Wilk e Jarque-Bera applicati agli errori del modello DSM usato per prevedere i 474 dati di calibrazione.

Tipologia di test	Statistica del test	df	p-value
Shapiro-Wilk	0.968	–	1.176 exp(-8)
Jarque-Bera	109.024	2	< 2.2 exp(-16)

Il  $p$ -value riportato nella tabella I.14 per entrambi i test è molto basso confrontato ai livelli di significatività usualmente considerati. Questo risultato fa propendere per il rifiuto dell'ipotesi nulla, che è la normalità della distribuzione degli errori. Questa conclusione sembrerebbe in contrasto con i valori di asimmetria e curtosi e con l'aspetto dell'istogramma. Inoltre il diagramma quantile-quantile mostra che solo una piccola parte dei quantili della distribuzione degli errori devia dalla linea bisettrice. Bisogna considerare che a causa della numerosità del campione i due test di normalità risultano molto severi.

Svolgendo il  $t$ -test sui 44 periodi di validazione, si è concluso che l'errore medio non è statisticamente diverso da zero. La statistica  $t$  calcolata sugli errori del DSM è -0.7441655 e la corrispondente probabilità di osservare questo set di errori qualora l'ipotesi nulla fosse valida è 0.7695881. Questo valore è generalmente considerato troppo alto per rifiutare l'ipotesi nulla.

L'istogramma degli errori e il Q-Q plot (diagramma quantile-quantile) sono riportati nella figura I.23, mentre i risultati dei test di Shapiro-Wilk e Jarque-Bera sono presentati nella tabella I.15.



**Fig. I.23:** (a) Iistogramma di frequenza degli errori calcolati sui 44 periodi di validazione. (b) Grafico quantile-quantile (distribuzione normale ipotizzata) che descrive l'andamento degli errori del modello DSM applicato ai 44 dati di validazione.

**Tab. I.15:** Test di normalità Shapiro-Wilk e Jarque-Bera applicati agli errori del modello DSM usato per prevedere i 44 dati di validazione.

Tipologia di test	Statistica del test	df	p-value
Shapiro-Wilk	0.9805	-	0.6542
Jarque-Bera	0.3549	2	0.8374

Il  $p$ -values nella tabella I.15 è molto alto confrontato con i livelli di significatività ai quali si fa riferimento in entrambi i test. Questo risultato fa propendere per l'accettare l'ipotesi nulla, ossia la normalità della distribuzione degli errori.

### 1.2.5 Discussione sui risultati ottenuti

In questo paragrafo si è concentrata l'attenzione sul problema del monitoraggio e della previsione dell'inquinamento acustico nelle aree urbane. È stata effettuata l'analisi statistica di un set di livelli di rumorosità notturna, ottenuti da una stazione di monitoraggio a Messina. Queste misurazioni sono state adottate per la costruzione e la validazione di un modello basato sull'analisi della serie storica. L'obiettivo principale è stato quello di prevedere i livelli di esposizione alla rumorosità. Questa metodologia parte dall'assunzione che il livello acustico nel tempo è il risultato della composizione di varie componenti: l'andamento di lungo periodo (trend), che è funzione del tempo ed è ottenuto dal liscio (smoothing) dei dati osservati; una componente ricorsiva (stagionalità), che descrive la periodicità del fenomeno; ed infine una componente irregolare, non deterministica, che può essere considerata con tecniche

probabilistiche. Il modello adottato è di tipo misto: moltiplicativo tra il trend e la stagionalità e additivo per considerare la componente irregolare.

È stato considerato un primo set di 321 dati, e grazie all'applicazione di test statistici, è stata evidenziata la presenza di fluttuazioni periodiche. Su questo set di dati è stato costruito un primo modello, considerando una periodicità settimanale, confermata dalla forte autocorrelazione in corrispondenza di un ritardo pari a 7 periodi.

Utilizzando questo primo modello è stato ricostruito un intervallo di 26 misurazioni mancanti ed è stato possibile ottenere un set di dati completo di 500 periodi da poter analizzare. Lo studio del correlogramma di questo ampio set di misurazioni ha confermato la periodicità settimanale dei dati ( $k_1 = 7$ ). Successivamente è stato ottenuto un set di valori privi di questa prima stagionalità grazie all'applicazione di una media mobile centrata di ampiezza pari a 7 periodi. È stato costruito il correlogramma di questo nuovo set di valori ed è stata evidenziata una seconda periodicità. Le nuove fluttuazioni periodiche sono risultate di più bassa frequenza: la seconda stagionalità è di circa 4 mesi, ossia  $k_2 = 125$ . Una possibile ipotesi sulla natura di questa seconda periodicità nei dati è che l'aumento di emissioni acustiche sia registrato in periodi dell'anno corrispondenti ad un incremento del flusso turistico verso la Sicilia. Infatti i picchi di periodicità 125 si registrano in concomitanza alle festività estive e a quelle natalizie. È importante notare che questa ipotesi è accreditata anche dal fatto che la periodicità  $k = 125$  si evidenzia in questo set di misure notturne, dove è lecito ipotizzare che la rumorosità è legata alle attività turistiche invece che a quelle commerciali, che influenzano maggiormente le misure diurne utilizzate nella prima sezione di questo capitolo.

A questo punto il modello a singola stagionalità (SSM) è stato migliorato considerando anche questa seconda periodicità evidenziata sul set di misurazioni esteso facendo così ottenere il più sofisticato modello a doppia stagionalità (DSM). I modelli SSM e DSM sono stati validati comparando le previsioni con 44 misure reali (non usate nella fase di calibrazione). Questi dati di validazione sono stati anche usati per un confronto quantitativo tra le prestazioni dei due modelli. Il modello a doppia stagionalità mostra prestazioni migliori in termini di più bassa deviazione standard della distribuzione degli errori e di una media più vicina allo zero. Inoltre l'applicazione dei test di normalità confermano l'ipotesi di distribuzione normale degli errori nella fase di validazione.

### 1.3 Un modello di previsione basato sull'analisi delle serie storiche applicato al consumo di energia elettrica

Al giorno d'oggi una gestione efficiente dei flussi energetici è molto importante nei grandi agglomerati urbani. Ci sono diversi benefici che possono derivare da una accurata descrizione e previsione dei consumi elettrici. Il primo è relativo alla gestione del sistema energetico della città. Il fornitore di energia elettrica richiede ad ogni grande consumatore di dichiarare preventivamente il fabbisogno energetico per un determinato periodo di tempo. Un secondo vantaggio è di tipo economico: il costo dell'energia in eccesso, rispetto a quello del fabbisogno stabilito per un'utenza, è molto più alto. Ad esempio le compagnie di trasporto devono dichiarare il consumo previsto in un certo intervallo di tempo e, se il consumo è superiore a quello dichiarato, l'energia in eccesso è comprata al doppio del prezzo, mentre se il consumo è inferiore, la differenza è riacquistata ad un prezzo più basso dal distributore. Le conseguenze economiche per una società sono facilmente immaginabili. Un beneficio ulteriore di un buon modello previsionale è l'opportunità di sviluppare varie strategie di affari, basate sulla previsione del consumo energetico in differenti scenari al variare dei percorsi e del numero di veicoli in transito. L'obiettivo è quello di calcolare il compromesso più remunerativo tra riduzione della richiesta energetica e offerta di un adeguato servizio ai clienti.

È importante sottolineare che in molte nazioni progredite, al fine di migliorare la gestione energetica sulla rete elettrica, alcuni consumatori di energia rilevanti hanno la possibilità di dividere i propri carichi in una parte distaccabile e in una che necessita di continuità di alimentazione. Ad esempio nel settore dei trasporti, il motore elettrico degli autobus richiede disponibilità continua di alimentazione elettrica (si considerino in particolare tram e filobus sempre più diffusi a causa del ridotto inquinamento locale), ma i sistemi di riscaldamento elettrico costituiscono un carico distaccabile. Se la società di trasporto conosce il giusto peso dei due tipi di carico e può prevedere i due tipi di assorbimento (nel caso studiato ci si riferirà ad una rete di trasporto urbano prevalentemente servita da tram e filobus), è possibile partecipare su di una rete intelligente ad un sistema del tipo *Demand Response Resource* (DRR) [31, 32]. I programmi di domanda flessibile sono usati dai pianificatori del sistema elettrico e dagli operatori della rete per effettuare un vantaggioso bilanciamento tra domanda e offerta di energia. I programmi di domanda flessibile forniscono ai consumatori di intraprendere un ruolo significativo nella gestione della rete elettrica riducendo o traslando il loro assorbimento di energia durante i periodi di picco della richiesta seguendo tariffazione oraria differenziata o altre forme di incentivi finanziari [33].

Le DRR sono agenti sul lato della domanda che partecipano attivamente al mercato sia come acquirenti di elettricità che come venditori di servizi per il taglio del carico. L'obiettivo della domanda flessibile è rendere il carico un agente attivo nel bilanciare la fornitura e la domanda entrando in competizione fianco a fianco con le risorse della fornitura. Le DRR tagliano la loro richiesta in risposta al pagamento di incentivi per l'abbassamento del consumo elettrico in specifici intervalli di tempo. Per questa ragione una previsione affidabile dell'assorbimento può essere estremamente utile per progettare e utilizzare risorse a domanda flessibile.

In generale diversi modelli previsionali avanzati sono presenti in letteratura; tali modelli sono basati su differenti tecniche tipo reti neurali artificiali, *Support Vector Machines*, *fuzzy logic*, strumenti statistici, automi cellulari, diversi dei quali sono applicati alla previsione dell'assorbimento energetico (si guardi ad esempio [34-43]).

I modelli di analisi delle serie storiche (TSA) sono capaci di ricavare il trend, le componenti periodiche e casuali di un certo set di dati che varia col tempo. Possono essere usati per la previsione della rumorosità da traffico veicolare come nei paragrafi precedenti, mostrando buone prestazioni anche in confronto ad altre tecniche. Altre applicazioni vantaggiose dei

modelli TSA possono essere la previsione di componenti di inquinanti gassosi che evolvono durante un certo intervallo di tempo. Ad esempio è stata modellata con queste tecniche la concentrazione oraria di ossido di carbonio nella zona di Monterrey (Mexico).

In questa sezione un modello TSA a stagionalità multipla è costruito e applicato al consumo elettrico del trasporto locale a Sofia (Bulgaria). L'obiettivo è ottenere una modellazione adeguata sia a descrivere il processo, sia ad essere usata per prevedere l'elettricità richiesta in periodi di tempo futuri.

### 1.3.1 Presentazione del modello

La tipologia di analisi delle serie storiche adottata in questo paragrafo (TSA) è largamente adottata in diverse discipline come l'economia, la fisica, l'ingegneria, la matematica (vedere ad esempio [44-48]). Nei paragrafi precedenti queste tecniche sono state adottate per la previsione della rumorosità da traffico veicolare e, in altre pubblicazioni, per l'inquinamento dell'aria riuscendo ad ottenere buoni risultati.

L'assunzione generale di questo modello consente di riprodurre l'andamento dei dati e di predirne i futuri valori componendo il trend e la periodicità della serie storica aggiungendo una componente di errore ottenuta analizzando i residui nella fase di calibrazione. L'ultima componente è utile a compensare oscillazioni nei dati dovute alla componente casuale della serie storica. In particolare il modello usato è moltiplicativo tra le componenti di trend e stagionalità e additivo per la componente casuale.

Nelle sezioni precedenti è stata fornita una dettagliata descrizione del modello TSA base e in particolare l'assunzione generale è presentata nella formula I.14.

In questa applicazione il trend è stato calcolato come regressione lineare sui dati osservati.

E' importante sottolineare che più è marcata la periodicità della serie storica studiata, più accurata sarà la previsione del modello adottato. Quando nei dati vengono rilevate due periodicità è utile adottare un modello a doppia stagionalità come quello presentato nella sezione 1.2, dunque la formula usata in questo caso dal modello a doppia stagionalità (DSM) sarà la I.15, nella quale  $\bar{S}_{1,i}$  e  $\bar{S}_{2,j}$  sono i due diversi coefficienti di stagionalità.

Nel caso studiato in questa sezione, come verrà illustrato in seguito, il modello DSM non riesce a seguire le fluttuazioni di lungo periodo inverno-estate del consumo di elettricità. Dunque è stato deciso di introdurre grazie ad un fattore correttivo un terzo coefficiente ottenuto dividendo il valore medio del consumo elettrico misurato nel mese *h-esimo* (con *h* variabile da 1 a 12) per il valore medio del trend stimato nello stesso mese:

$$\bar{S}_{3,h} = \frac{\sum_{t=a_h}^{b_h} Y_t}{\sum_{t=a_h}^{b_h} T_t}, \quad (I.29)$$

nella quale  $a_h$  e  $b_h$  sono i numeri progressivi della prima e dell'ultima ora del mese *h-esimo* nel set di dati considerato.

La formula previsionale del risultante modello a tripla stagionalità (TSM) è:

$$\hat{Y}_t = T_t \bar{S}_{1,i} \bar{S}_{2,j} \bar{S}_{3,h}. \quad (I.30)$$

Dopo la fase di calibrazione la previsione può essere ottenuta tramite la formula finale:

$$\hat{Y}_t = T_t \bar{S}_{1,i} \bar{S}_{2,j} \bar{S}_{3,h} + m_e, \quad (\text{I.31})$$

che include anche  $m_e$ , la media dell'errore nella fase di calibrazione.

Una serie storica è definita lineare se può essere espressa come combinazione lineare di  $Z_t$  variabili casuali indipendenti, con  $\psi_j$  parametri sconosciuti [22]:

$$X_t = \sum_{j=-\infty}^{+\infty} \psi_j Z_{t-j}. \quad (\text{I.32})$$

Se tale condizione non è verificata, la serie storica è definita non-lineare. La non-linearità implica che i modelli usuali stocastici adottati per l'analisi delle serie storiche, ad esempio gli ARMA auto-regressivi a media mobile, non sono adeguati. Verrà mostrato che il modello presentato è capace di fornire previsioni adeguate del consumo elettrico anche se la serie studiata è non-lineare.

Per verificare la linearità, possono essere eseguiti test statistici specifici. Si è scelto di utilizzare i test di Lee-White-Granger (LWG) [46] e di Terasvirta-Lin-Granger (TLG) [47].

Una serie storica è stazionaria in senso debole se la media non dipende dal tempo e se la funzione di autocovarianza è indipendente da  $t$  per ogni ritardo scelto [22].

Al fine di verificare la stazionarietà della serie studiata possono essere implementati diversi test statistici basati sulla ricerca di radici unitarie. Per la serie storica di assorbimento elettrico sono stati utilizzati i test di stazionarietà Augmented Dickey-Fuller (ADF) [48] e Phillips-Perron (PP) [49]. Il risultato dell'applicazione dei due test mostrerà che la serie studiata può essere considerata stazionaria.

### 1.3.2 Analisi dei dati

Come caso studio è stato preso in considerazione il consumo elettrico del trasporto pubblico locale nella città di Sofia (Bulgaria).

Il trasporto elettrico a Sofia comincia nel 1901. Attualmente a Sofia i tram e i filobus elettrici costituiscono una parte rilevante del trasporto pubblico trasportando ogni anno milioni di passeggeri. Nel 2008 ad esempio 198 milioni di passeggeri sono stati trasportati.

La potenza è fornita da 24 stazioni di raddrizzamento con una capacità totale installata di oltre 125950 kW. La rete prevede oltre 263 km di rotaie per tram e 257 km di percorsi per filobus, e la rete conta più di 740 chilometri di cavi [50].

Per il fatto che l'estate e l'inverno mostrano una forte variazione nelle temperature medie con un conseguenziale diverso uso del sistema di riscaldamento elettrico, e per il fatto che in estate sono previste meno vetture circolanti, si registra una minore richiesta di elettricità a seconda della stagione climatica dell'anno. Fluttuazioni periodiche si verificano anche a seconda della natura del giorno della settimana lavorativo o festivo; non da meno sono le variazioni a seconda dell'ora del giorno considerata. Pertanto si intuiscono periodicità orarie e settimanali.

In generale negli ultimi decenni, il consumo elettrico in Bulgaria è cresciuto ma grazie agli impianti di produzione termonucleari la nazione riusciva a soddisfare pienamente la richiesta interna ed era capace di esportare parte della potenza elettrica prodotta. Tuttavia dal 2006 l'elettricità esportata si è ridotta, a causa della chiusura di alcuni reattori nucleari obsoleti.

Questi cambiamenti nel mix produttivo richiedono una più attenta gestione anche dei consumi locali a causa della diminuita disponibilità di energia sulla rete nazionale.

La società di trasporto *Transenergo*, con i suoi ingegneri elettrici è obbligata a dichiarare il consumo elettrico per ogni ora della successiva settimana. Una dichiarazione sbagliata compromette il prezzo dell'energia acquistata. Gli ingegneri elettrici hanno informazioni riguardanti i chilometri percorsi, la temperatura, il tipo di giorno festivo o lavorativo e con queste informazioni devono stimare il consumo elettrico necessario [34].

I dati di consumo in MWh sono verificati con un misuratore di energia elettrica che fornisce l'assorbimento orario durante la notte e il giorno. Il set di dati studiati è relativo agli anni dal 2011, 2012 e 2013; in particolare, le misurazioni che vanno dal 1° gennaio 2011 al 31 dicembre 2012 sono state usate nelle fasi di calibrazione e i dati raccolti a gennaio 2013 sono stati usati per la validazione del modello.

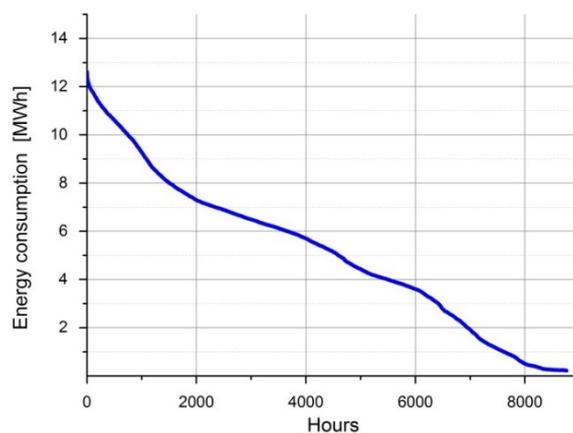
Il primo passo per la costruzione del modello, è l'analisi statistica del set di dati usato nelle fasi di calibrazione. La prima scelta è stata soffermarsi sul consumo elettrico orario misurato durante il 2011. Dopo questa prima valutazione è stata svolta un'analisi di lungo periodo usando come set di calibrazione le misure degli anni 2011 e 2012 e validando il modello su alcuni dati del 2013. Il primo set di calibrazione è costituito da 8760 dati di consumo orario, misurati in MWh, le cui statistiche riassuntive sono fornite nella tabella I.16.

Come può essere dedotto dagli indici di asimmetria e curtosi, la distribuzione dei dati può essere considerata normale. Inoltre l'alto valore della deviazione standard rispetto alla media, insieme al valore massimo e minimo misurati, mostrano una alta dispersione dei dati intorno alla media.

La curva di permanenza del carico, cioè il grafico del consumo di energia (in ordine decrescente), in funzione del numero di ore nelle quali tale valore di consumo è ottenuto e superato, è mostrata in figura I.23.

**Tab. I.16:** Statistiche riassuntive degli 8760 dati di calibrazione relativi al periodo del 2011.

Media [MWh]	Dev.Std. [MWh]	Mediana [MWh]	Min [MWh]	Max [MWh]	skew	kurt
5.14	3.12	5.28	0.22	12.62	0.17	-0.75



**Fig. I.23:** Consumo di elettricità nel 2011 diagrammato in ordine decrescente. L'asse delle ascisse riporta il numero di ore nelle quali il corrispondente consumo elettrico è stato superato.

**Tab. I.17:** Test di Ljung-Box e Box-Pierce applicati alle 8760 misure del set di calibrazione del 2011.

Test	$\chi^2$	d	p-value
Ljung-Box	53542.33	30	< 2.2e-16
Box-Pierce	78500.02	50	< 2.2e-16

**Tab. I.18:** Test di linearità di Lee-White-Granger (LWG) e Terasvirta-Lin-Granger (TLG) applicati agli 8760 dati del set di calibrazione del 2011.

Test	Statistica del test	df	p-value
LWG	37.4105	2	7.524e-09
TLG	35.4774	2	1.978e-08

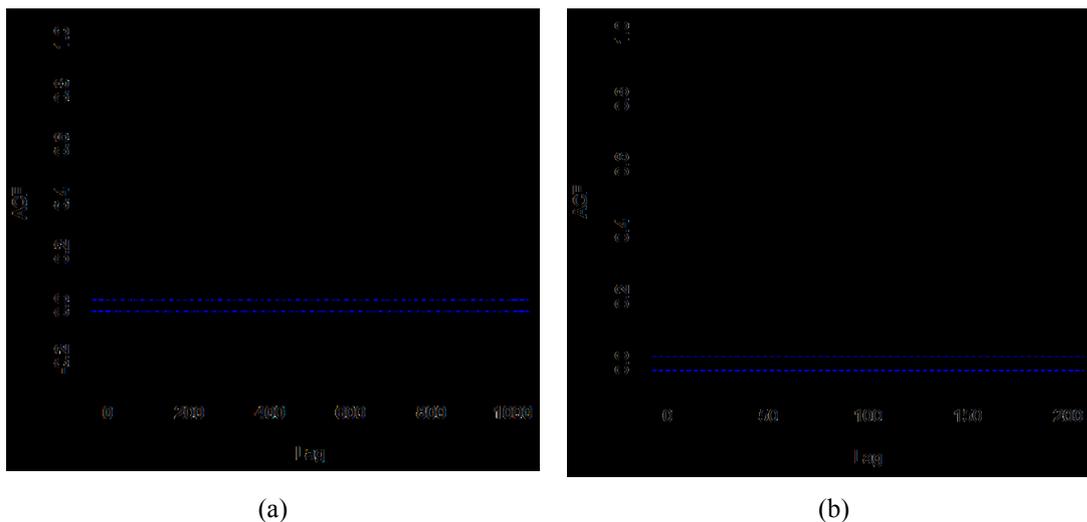
Nel paragrafo precedente è stata discussa la probabile presenza di tre periodicità nei dati: una oraria, una settimanale e una implementata su base mensile. Per verificare se i dati sono autocorrelati o meno i test di Ljung-Box (LB) and Box-Pierce (BP) sono stati eseguiti.

I risultati dei due test, riportati nella tabella I.17, mostrano un basso *p*-value, ossia la piccolissima probabilità di osservare il campione qualora l'ipotesi nulla fosse vera: dunque l'assenza di autocorrelazione nei dati può essere scartata.

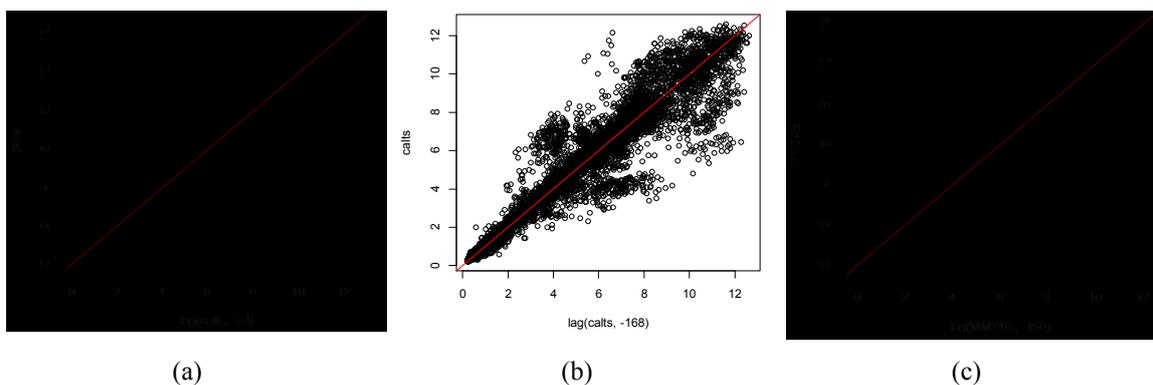
Sulla serie studiata sono stati eseguiti anche i test di linearità mediante il programma "R". In tabella I.18 sono riportati i livelli di probabilità molto bassi che inducono a rifiutare l'ipotesi nulla ossia la linearità della serie. I risultati di questi test e le buone capacità previsionali del modello costruito evidenziano la capacità di quest'ultimo di riprodurre l'andamento anche di serie storiche non lineari.

L'autocorrelazione presente nella serie è stata studiata tramite i correlogrammi riportati in figura I.24. È evidente la presenza di diverse periodicità. In particolare il massimo valore del coefficiente di autocorrelazione è ottenuto in corrispondenza di un ritardo pari a 24 ore (periodicità giornaliera) e un ritardo pari a 168 ore (periodicità settimanale). Questa seconda stagionalità è visibile anche nel correlogramma di figura I.24(b) realizzato sui valori della prima media mobile centrata di ampiezza pari a 24 periodi.

La figura I.25 riporta i diagrammi di autodispersione dei tre differenti set di dati: in tutti e tre i casi i dati sono addensati sulla bisettrice confermando la presenza dei ritardi considerati. La figura I.25(a) riporta i dati misurati in funzione degli stessi valori traslati (ritardati) di 24 ore. Due agglomerati sono evidenti ai lati della bisettrice mostrando la presenza di ulteriori periodicità. La figura I.25(b) riporta i dati misurati in funzione degli stessi valori traslati di 168 ore (una settimana). La figura I.25(c) riporta i valori della media mobile centrata di ampiezza 24 diagrammata in funzione degli stessi valori traslati di 168 ore. Il grafico mostra un addensamento generale intorno alla bisettrice con alcune variazioni simmetriche rispetto a questa. Questo risultato sembra mostrare la presenza di ulteriori periodicità con frequenza più bassa.



**Fig. I.24:** (a) Grafico di autocorrelazione (correlogramma) dei dati del 2011 in funzione della periodicità considerata. (b) Correlogramma dei valori della prima media mobile centrata applicata ai dati del 2011.

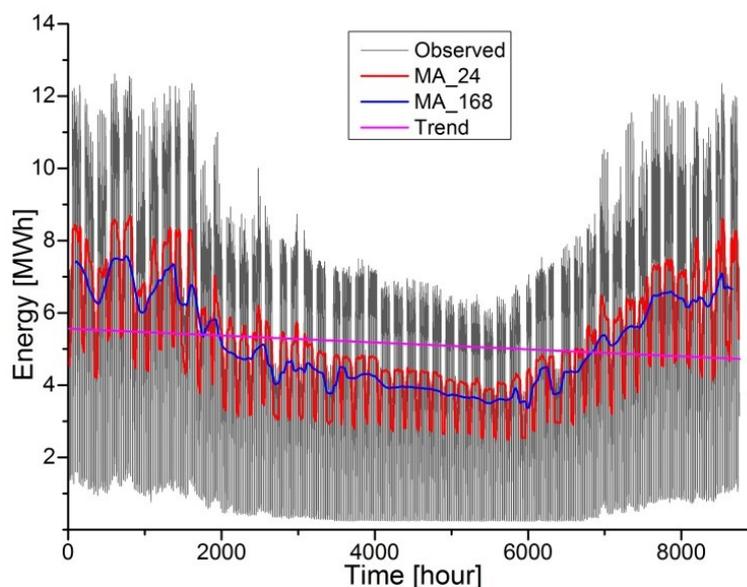


**Fig. I.25:** (a) Grafico di autodispersione del set di dati del consumo elettrico del 2011 evidenziato in funzione degli stessi dati traslati di 24 ore. (b) Grafico di autodispersione del set di dati del consumo elettrico del 2011 evidenziato in funzione degli stessi dati traslati di 168 ore. (c) Grafico di autodispersione della media mobile di ampiezza 24 in funzione della stessa media mobile traslata di 168 ore, misurazioni del 2011.

### 1.3.3 Calibrazione sul dataset del 2011

Dopo aver riscontrato le giuste periodicità, il modello può essere implementato come descritto nei paragrafi precedenti. Le medie mobili sono mostrate nella figura I.26 insieme alla retta di trend.

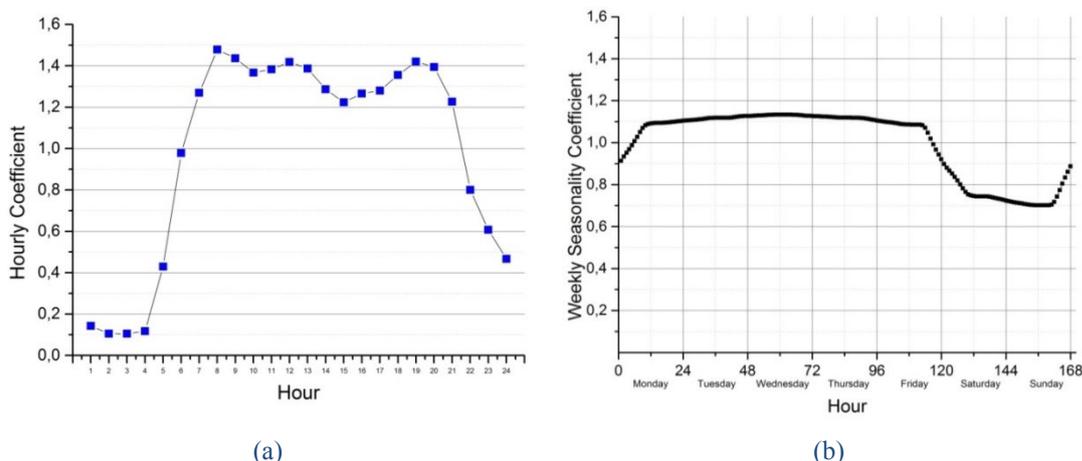
I parametri del modello, ossia i due parametri del trend e i 24 coefficienti della prima stagionalità (giornaliera) sono riportati nella tabella I.19 e in figura I.27(a), mentre i 168 coefficienti della seconda stagionalità (settimanale) sono mostrati nella figura I.27(b).



**Fig. I.26:** Grafico delle due medie mobili centrate e della linea di trend. In nero i dati reali del 2011, in violetto la linea di trend, in rosso la prima media mobile (ampiezza 24), in blu la seconda media mobile (ampiezza 168).

**Tab. I.19:** Parametri del modello stimati sui dati di consumo elettrico del 2011.  $b_0$  e  $b_1$  sono rispettivamente l'intercetta e la pendenza della linea di trend, mentre  $\bar{S}_i$  sono i coefficienti orari, per ricostruire la periodicità giornaliera, negli intervalli di tempo dall'ora  $i-1$  all'ora  $i$ .

Valori stimati dei parametri del modello			
$b_0$	5.55998	$b_1$	-0.0000957
$\bar{S}_1$	0.14318	$\bar{S}_{13}$	1.38711
$\bar{S}_2$	0.10604	$\bar{S}_{14}$	1.28621
$\bar{S}_3$	0.10540	$\bar{S}_{15}$	1.22370
$\bar{S}_4$	0.11779	$\bar{S}_{16}$	1.26628
$\bar{S}_5$	0.42944	$\bar{S}_{17}$	1.28007
$\bar{S}_6$	0.97802	$\bar{S}_{18}$	1.35565
$\bar{S}_7$	1.26947	$\bar{S}_{19}$	1.41998
$\bar{S}_8$	1.47812	$\bar{S}_{20}$	1.39447
$\bar{S}_9$	1.43660	$\bar{S}_{21}$	1.22622
$\bar{S}_{10}$	1.36739	$\bar{S}_{22}$	0.80087
$\bar{S}_{11}$	1.38302	$\bar{S}_{23}$	0.60751
$\bar{S}_{12}$	1.41843	$\bar{S}_{24}$	0.46727



**Fig. I.27:** (a) Coefficienti orari usati per ricostruire la periodicità giornaliera nei dati del 2011. (b) Coefficienti orari usati per ricostruire la periodicità settimanale nei dati del 2011.

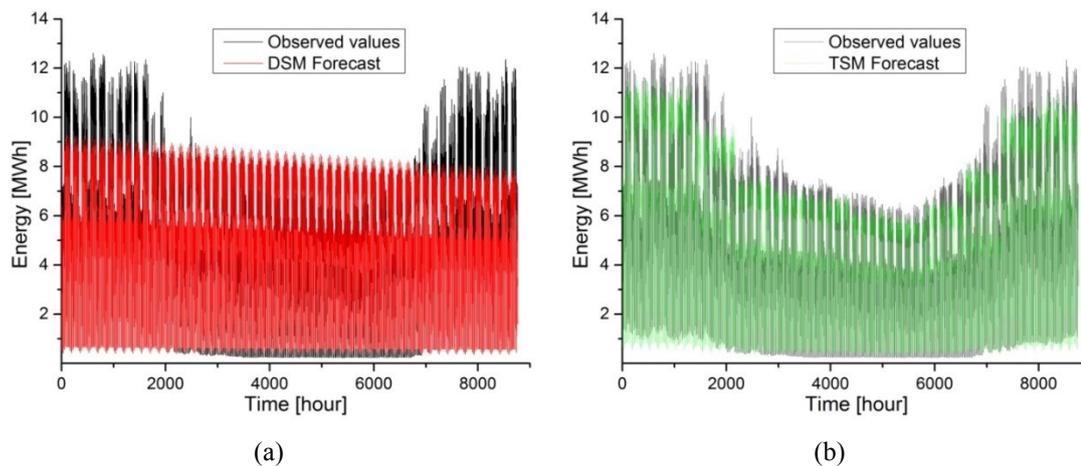
Con questa procedura un modello a doppia stagionalità (DSM) è stato costruito. I risultati delle previsioni del modello DSM sono mostrati nella figura I.28(a) insieme ai valori realmente misurati. È facile notare che le previsioni riescono a seguire le fluttuazioni locali (giornaliere e settimanali) ma è presente una periodicità di lungo periodo (bassa frequenza, mensile) che andrebbe considerata. Per tener conto di questa evidenza, come descritto in precedenza, è stato introdotto un terzo fattore che descrive più accuratamente l'andamento mensile dei dati.

Questo terzo coefficiente di stagionalità è stato calcolato in accordo alla formula I.29, cioè dividendo il valore medio del consumo di elettricità misurato in ogni mese per il valore medio del trend stimato nello stesso mese.

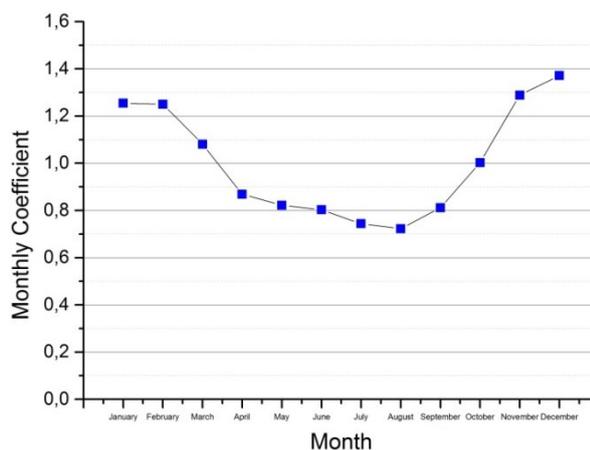
Questi 12 rapporti sono capaci di descrivere le variazioni di lungo termine della serie storica. I coefficienti mensili risultanti sono mostrati nella figura I.29 e indicano il più alto consumo di elettricità registrato durante i mesi freddi, dovuto probabilmente sia al più alto numero di veicoli in transito che ai sistemi di riscaldamento.

L'applicazione del terzo coefficiente al modello DSM, dà vita al modello a tripla stagionalità (TSM) le previsioni del quale sono mostrate in figura I.28(b) insieme ai valori realmente osservati.

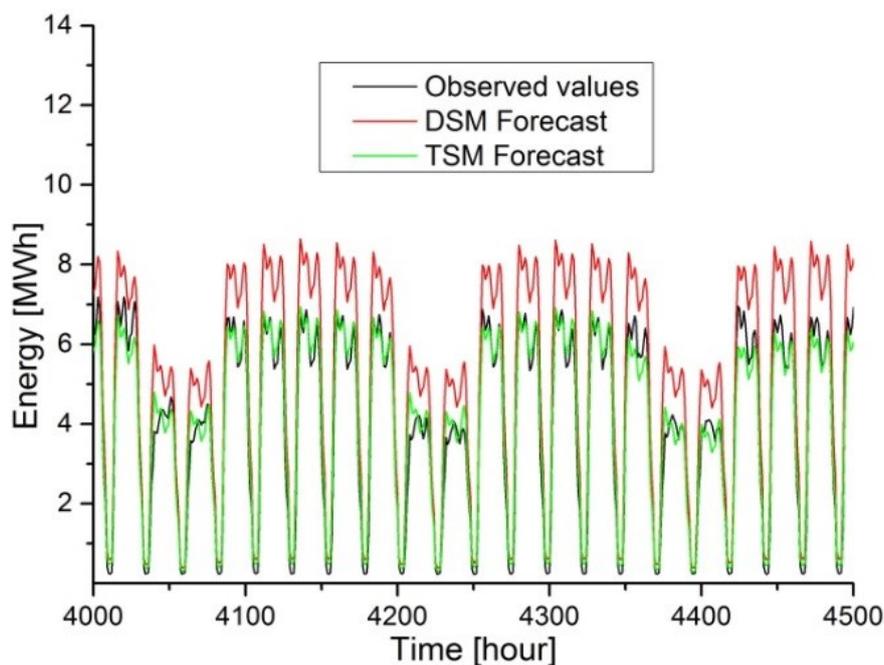
Al fine di mostrare il miglioramento prodotto dal terzo coefficiente di stagionalità, il grafico delle previsioni dei modelli DSM e TSM e dei dati misurati durante un intervallo di tempo estivo (dall'ora 4000 alla 4500), è riportato nella figura I.30. Il TSM si accorda meglio ai dati reali in quasi ogni intervallo di tempo, mentre il DSM sottostima i valori reali durante l'inverno e li sovrastima nei mesi estivi: le poche oscillazioni casuali sono trascurate da entrambi i modelli.



**Fig. I.28:** (a) Consumo di elettricità osservato e previsioni del modello a doppia stagionalità evidenziati nell'intervallo temporale del 2011. (b) Consumo di elettricità osservato e previsioni del modello a tripla stagionalità relativi ai dati del 2011.



**Fig. I.29:** Coefficienti mensili usati dal modello per ricostruire il terzo andamento stagionale del consumo elettrico relativo al 2011.



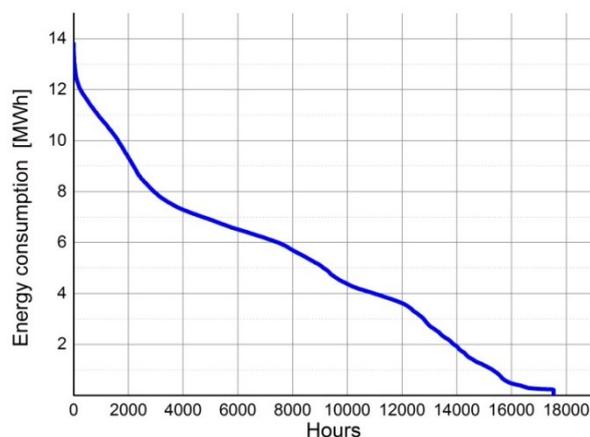
**Fig. I.30:** Grafico del consumo elettrico durante l'intervallo temporale dall'ora 4000 alla 4500 del 2011: la linea nera rappresenta i dati reali, la rossa rappresenta le previsioni del modello DSM e la linea verde rappresenta le previsioni del modello TSM.

#### 1.3.4 Calibrazione sul dataset del 2011 e del 2012

Il secondo set di calibrazione è fatto da 17544 dati orari di consumo elettrico, misurato in megawattora (MWh), le statistiche riassuntive sono riportate nella tabella I.20. gli indici di asimmetria e curtosi suggeriscono una distribuzione normale all'origine di questi dati. Una importante considerazione da fare è che anche aggiungendo i dati del 2012 raddoppiando il campione analizzato, gli indici statistici considerati sono all'incirca gli stessi. Questa è una prova della natura stazionaria di questa serie storica, come confermato dai test di stazionarietà.

**Tab. I.20:** Statistiche riassuntive dei 17544 dati di calibrazione relativi ai periodi del 2011 e 2012.

Media [MWh]	Dev.Std. [MWh]	Mediana [MWh]	Min [MWh]	Max [MWh]	skew	kurt
5.16	3.18	5.25	0	13.81	0.24	-0.64



**Fig. I.31:** Consumo di elettricità durante il 2011 e 2012 diagrammato in ordine decrescente. L'asse delle ascisse riporta il numero di ore nelle quali il corrispondente assorbimento elettrico è stato superato.

La curva di permanenza del carico dei dati del 2011 e del 2012 è riportata in figura I.31. Si ricorda che l'asse delle ascisse rappresenta il numero di ore nelle quali un certo valore di consumo è raggiunto e superato.

La presenza di autocorrelazione nel set di dati esteso e la non linearità della serie sono confermate dai test statistici presentati nei paragrafi precedenti, i risultati dei quali sono mostrati nelle tabelle I.21 e I.22.

Il basso  $p$ -value dei test ADF e PP (tabella I.23) evidenzia l'assenza di radici unitarie nel processo, questo risultato conferma l'ipotesi che il processo è stazionario: non vi sono cambiamenti significativi della media e della varianza considerando diversi intervalli temporali.

**Tab. I.21:** Test statistici di Ljung-Box e Box-Pierce applicati alle 17544 misure del set di dati di calibrazione.

Test	$\chi^2$	$d$	$p$ -value
Ljung-Box	109874.6	30	2.2e-16
Box-Pierce	160968.7	50	2.2e-16

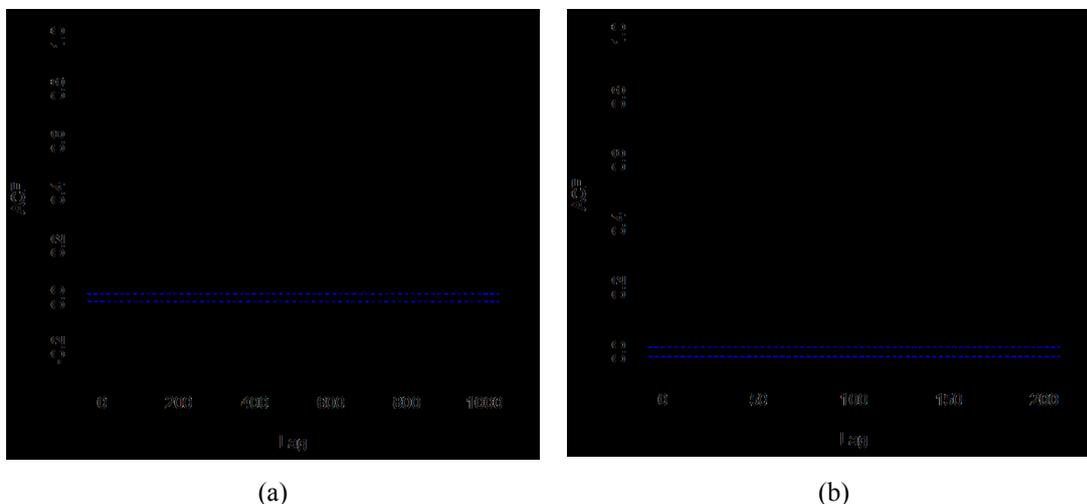
**Tab. I.22:** Test di linearità di Lee-White-Granger (LWG) e Terasvirta-Lin-Granger (TLG) applicati ai 17544 dati di calibrazione.

Test	Statistica del test	$df$	$p$ -value
LWG	78.086	2	2.2e-16
TLG	76.624	2	2.2e-16

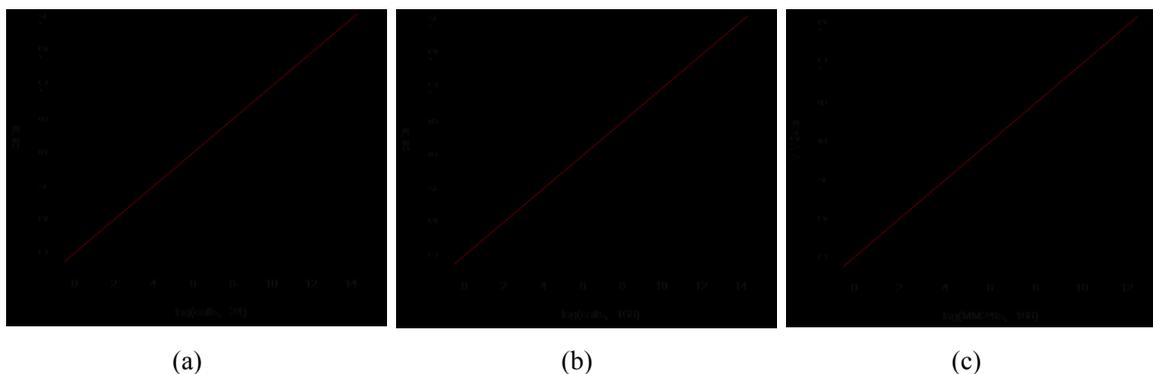
**Tab. I.23:** Test di stazionarietà di Dickey-Fuller e Phillips-Perron applicati ai 17544 dati di calibrazione.

Test	Statistica del test	Lag	$p$ -value
Augmented Dickey-Fuller	-10.2615	25	0.01
Phillips-Perron	-27.1904	14	0.01

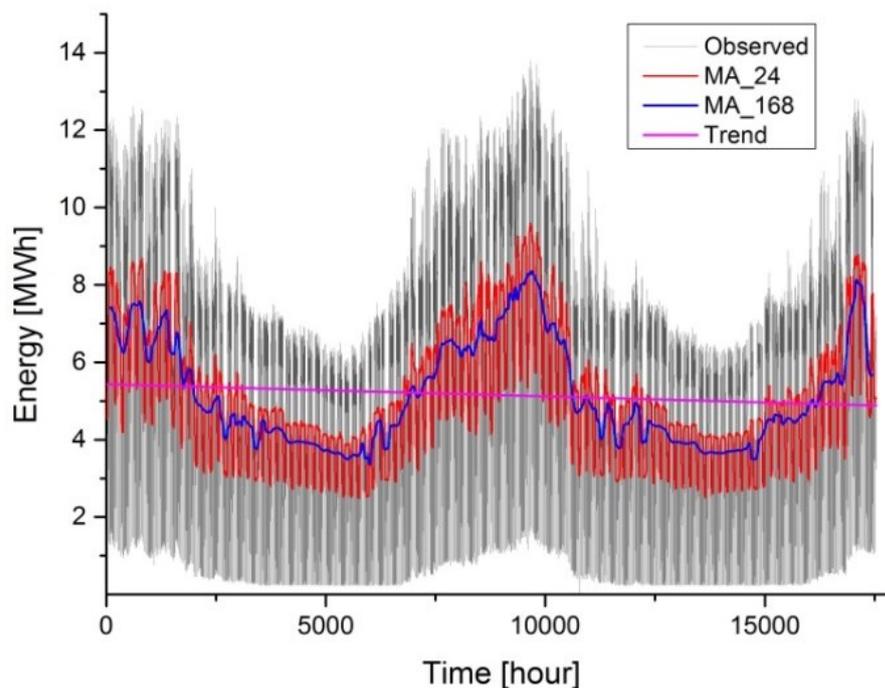
Le figure I.32 e I.33 mostrano che i dati aggregati del 2011 e del 2012 hanno lo stesso andamento dell'autocorrelazione rispetto al set di misurazioni di un solo anno, suggerendo che il modello costruito per la serie storica estesa può essere sostanzialmente simile al precedente.



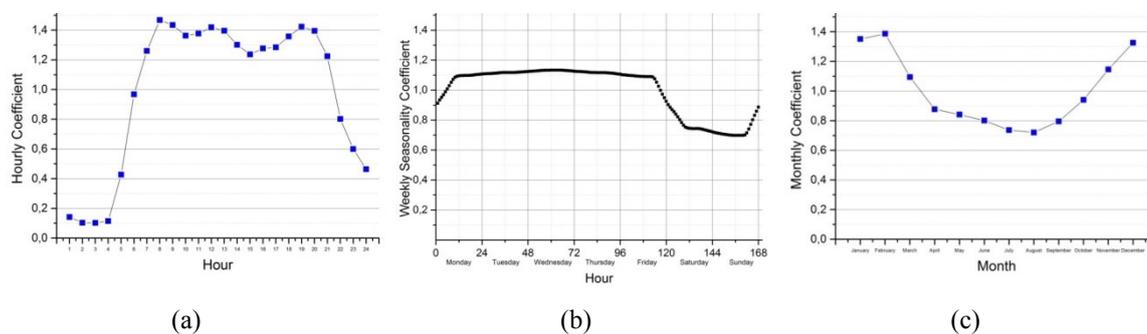
**Fig. I.32:** (a) Diagramma di autocorrelazione (correlogramma) in funzione della periodicità scelta per i dati del 2011 e 2012. (b) Correlogramma dei valori della prima media mobile centrata di ampiezza 24.



**Fig. I.33:** (a) Grafico di autodispersione del consumo elettrico durante il 2011 e 2012 evidenziato in funzione degli stessi dati traslati di 24 ore. (b) Grafico di autodispersione dei dati di consumo elettrico del 2011 e 2012 evidenziato in funzione degli stessi dati traslati di 168 ore. (c) Grafico di autodispersione della media mobile di ampiezza 24 in funzione della stessa media mobile traslata di 168 ore, misurazioni del 2011 e 2012.



**Fig. I.34:** Grafico delle due medie mobili centrate e della linea di trend. In nero i dati reali del 2011 e 2012, in violetto la linea di trend, in rosso la prima media mobile (ampiezza 24), in blu la seconda media mobile (ampiezza 168).

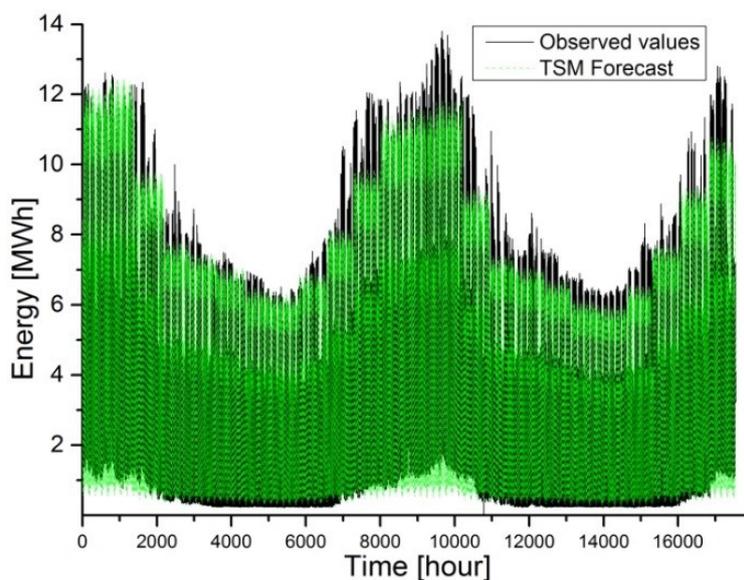


**Fig. I.35:** (a) Coefficienti orari usati per ricostruire la periodicità giornaliera nei dati del 2011 e 2012.  
 (b) Coefficienti orari usati per ricostruire la periodicità settimanale nei dati del 2011 e 2012.  
 (c) Coefficienti mensili usati dal modello per ricostruire il terzo andamento stagionale del consumo elettrico relativo al 2011 e 2012.

Una volta che è stata confermata la stagionalità multipla, le medie mobili e il trend (figura I.34) sono stati calcolati: si guardino la tabella I.24 e la figura I.35. A questo punto si può effettuare un confronto grafico sovrimponendo le previsioni ai dati reali come in figura I.36.

**Tab. I.24:** Parametri del modello stimati sui dati di consumo elettrico del 2011 e 2012.  $b_0$  e  $b_1$  sono rispettivamente l'intercetta e la pendenza della linea di trend, mentre  $\bar{S}_i$  sono i coefficienti orari, per ricostruire la periodicità giornaliera, negli intervalli di tempo dall'ora  $i-1$  all'ora  $i$ .

Valori stimati dei parametri del modello			
$b_0$	5.4329841	$b_1$	-3.129E-05
$\bar{S}_1$	0.14232	$\bar{S}_{13}$	1.39581
$\bar{S}_2$	0.10372	$\bar{S}_{14}$	1.30130
$\bar{S}_3$	0.10293	$\bar{S}_{15}$	1.23696
$\bar{S}_4$	0.11504	$\bar{S}_{16}$	1.27697
$\bar{S}_5$	0.42737	$\bar{S}_{17}$	1.28428
$\bar{S}_6$	0.96794	$\bar{S}_{18}$	1.35810
$\bar{S}_7$	1.26038	$\bar{S}_{19}$	1.42362
$\bar{S}_8$	1.46817	$\bar{S}_{20}$	1.39512
$\bar{S}_9$	1.43488	$\bar{S}_{21}$	1.22463
$\bar{S}_{10}$	1.36337	$\bar{S}_{22}$	0.80240
$\bar{S}_{11}$	1.37740	$\bar{S}_{23}$	0.60029
$\bar{S}_{12}$	1.41945	$\bar{S}_{24}$	0.46441



**Fig. I.36:** Valori di potenza assorbita reali e previsti durante gli anni 2011 e 2012, ossia l'intervallo temporale di calibrazione. La linea nera rappresenta i valori osservati, la linea verde rappresenta i valori previsti dal modello a tripla stagionalità.

La calibrazione sui due anni dà risultati molto simili a quella fatta sul solo 2011, conformando la stazionarietà della serie e la caratterizzazione fortemente periodica. Il miglioramento più consistente è legato al terzo coefficiente (quello che riproduce le fluttuazioni mensili), che in questa fase si è potuto calcolare su un numero di periodi significativamente maggiore.

### 1.3.5 Analisi dell'errore e validazione

Al fine di valutare le prestazioni del modello calibrato su diversi dati, è stata effettuata l'analisi degli errori di previsione sia del modello DSM che di quello TSM, sui dati del 2011, e di quello TSM sul set di misurazioni esteso 2011 più 2012. Inoltre una validazione del modello più avanzato, TSM calibrato sui dati 2011 più 2012, è stata eseguita sulle 744 misurazioni orarie di gennaio 2013, dunque si è potuto testare il modello su dati non usati per la stima dei parametri e dei coefficienti. Si ricorda che l'errore di previsione è stato sempre calcolato secondo la formula I.8.

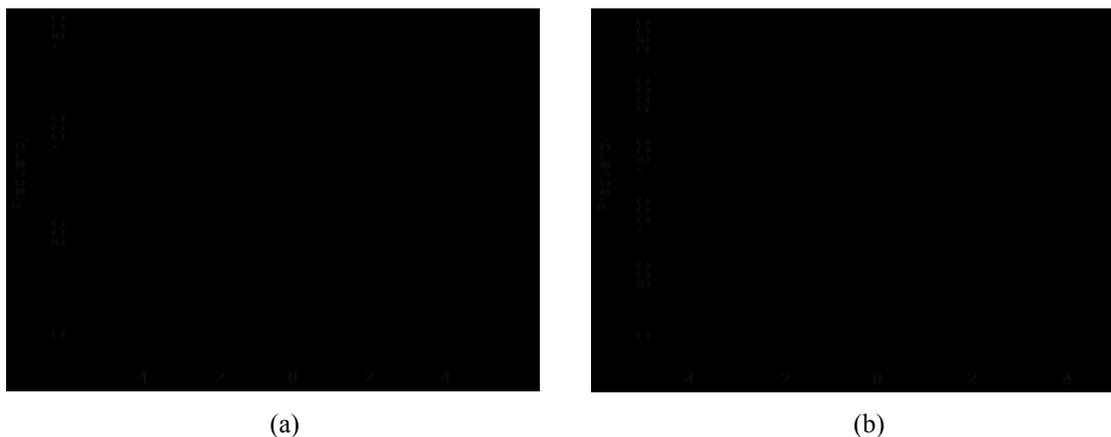
Confrontando le statistiche dell'errore del modello DSM con quelle del TSM (tabella I.25) possiamo notare che la deviazione standard decresce di molto passando dalla doppia stagionalità alla tripla. Anche la mediana e l'intervallo tra errore massimo e minimo migliorano passando al modello più avanzato.

**Tab. I.25:** Statistiche riassuntive della distribuzione degli errori di previsione commessi dai modelli a doppia (DSM) e tripla (TSM) stagionalità. Errori valutati sul set di dati di calibrazione relativi al 2011.

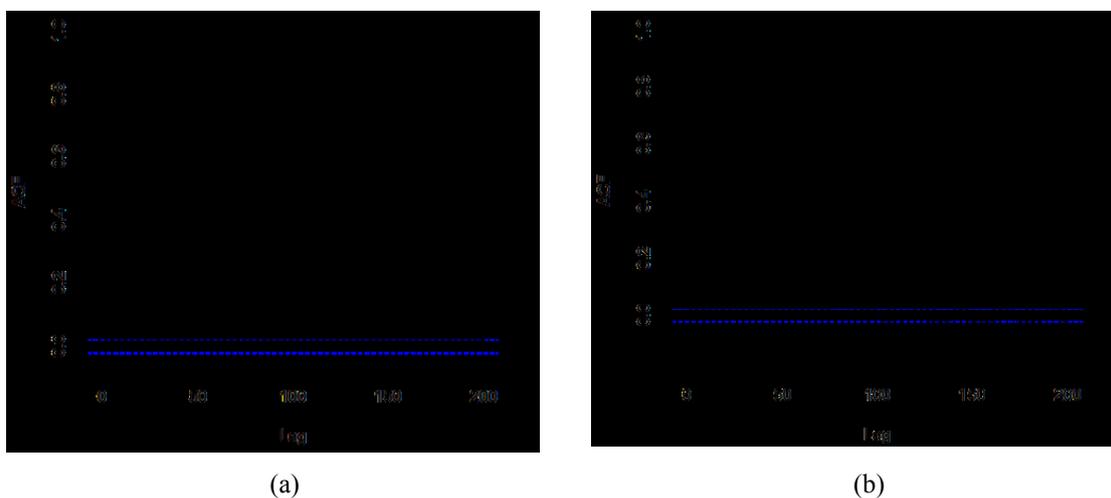
Modello	Media [MWh]	Dev.Std. [MWh]	Mediana [MWh]	Min [MWh]	Max [MWh]
DSM	0.02	1.49	-0.25	-4.86	4.92
TSM	0.02	0.81	0.03	-3.99	3.6

Nel caso del DSM, l'istogramma degli errori (figura I.37(a)) ha una marcata coda a destra, mentre nel caso del TSM la distribuzione in figura I.37(b) appare marcatamente tendente ad una normale, indicando che gli errori del modello più avanzato sono imputabili a fluttuazioni casuali.

Nella figura I.38 sono portati i correlogrammi degli errori dei due modelli: è evidente che per il DSM gli errori sono ancora fortemente autocorrelati, mentre per il TSM grazie al terzo coefficiente l'informazione estratta dalla serie è sensibilmente maggiore.



**Fig. I.37:** (a) Istogramma di frequenza degli errori calcolati applicando il modello DSM agli 8760 dati di calibrazione relativi al 2011. (b) Istogramma di frequenza degli errori calcolati applicando il modello TSM agli 8760 dati di calibrazione relativi al 2011.



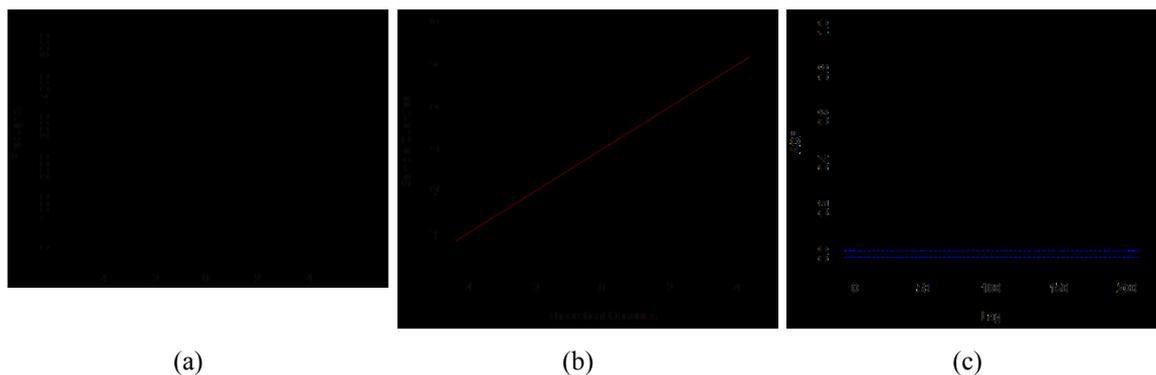
**Fig. I.38:** (a) Correlogramma degli errori di previsione commessi dal modello DSM applicato ai 2011 dati di calibrazione. (b) Correlogramma degli errori di previsione commessi dal modello TSM applicato ai 2011 dati di calibrazione.

Per la seconda analisi degli errori le statistiche riassuntive sono riportate nella tabella I.26. Per il fatto che il DSM si rivela peggiore anche in questo caso e per il fatto che il TSM si è dimostrato essere molto più efficace per questa serie storica di assorbimento energetico, si è deciso di procedere con le analisi e la validazione solo con il modello più avanzato.

L'istogramma di frequenza, il diagramma quantile-quantile e il correlogramma relativi all'applicazione del TSM sono riportati nella figura I.39. sia l'istogramma che la simmetria del diagramma quantile-quantile mostrano che l'errore può essere considerato distribuito normalmente. Il correlogramma degli errori (figura I.39(c)) presenta ancora una correlazione residua non del tutto trascurabile.

**Tab. I.26:** Statistiche riassuntive della distribuzione degli errori di previsione commessi dai modelli a doppia (DSM) e tripla (TSM) stagionalità. Errori valutati sul set di dati di calibrazione relativi agli anni 2011 e 2012.

Modello	Media [MWh]	Dev.Std. [MWh]	Mediana [MWh]	Min [MWh]	Max [MWh]
DSM	0.02	1.6	-0.3	-5.23	7.11
TSM	0.02	0.9	0	-4.54	5.22



**Fig. I.39:** (a) Istogramma di frequenza degli errori calcolati applicando il modello TSM ai 17544 dati di calibrazione relativi agli anni 2011 e 2012. (b) Grafico quantile-quantile (distribuzione normale ipotizzata) che descrive l'andamento degli errori del modello TSM applicato ai 17544 dati di calibrazione (anni 2011 e 2012). (c) Correlogramma degli errori di previsione del modello TSM applicato ai dati del 2011 e 2012.

Al fine di capire se il modello a tripla stagionalità è capace di prevedere valori futuri di assorbimento elettrico è stato effettuato il confronto tra le previsioni e i valori reali (non inclusi nel set di calibrazione) di validazione. La scelta è stata di usare 744 misurazioni di assorbimento energetico relative a gennaio 2013 che è il periodo immediatamente successivo all'intervallo di calibrazione.

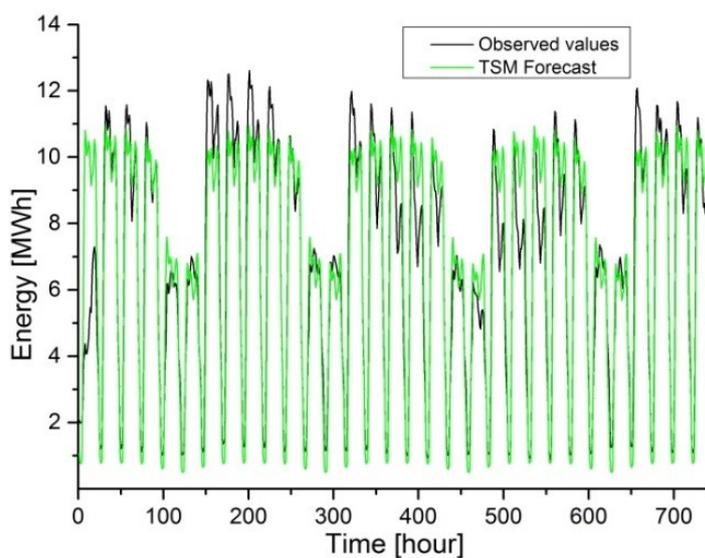
Il grafico dei risultati della validazione è riportato in figura I.40 nella quale i dati reali in nero e le previsioni in verde sono diagrammati in funzione del tempo. La linea delle previsioni del modello segue giustamente i valori osservati eccetto che per la prima parte dell'intervallo considerato, ossia il primo giorno dell'anno. In questo periodo, probabilmente a causa della bassa circolazione di veicoli dovuta alla festività, è osservato un basso assorbimento simile a quello dei fine settimana. Il modello TSM non può prevedere cambi locali nell'andamento periodico. È visibile questa leggera sovrastima anche nelle statistiche degli errori presentate in tabella I.27, in particolare guardando la disomogeneità tra l'errore minimo e il massimo. Nell'istogramma degli errori e nel diagramma quantile-quantile può essere notata una lunga coda a sinistra della distribuzione (figura I.41).

Trascurando questo problema circoscritto, gli errori sembrano normalmente distribuiti e sono molto poco autocorrelati (figura I.41(c)), mostrando dunque una caratterizzazione casuale. Questi elementi confermano le buone prestazioni previsionali del modello costruito.

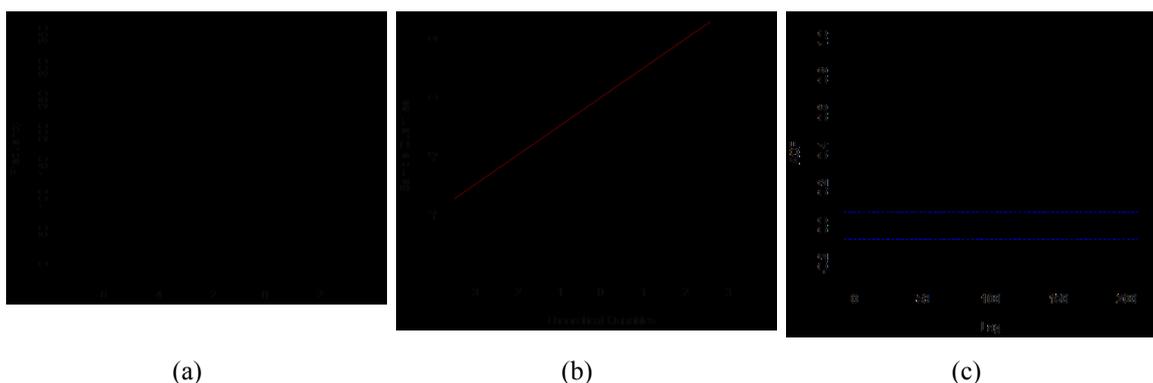
Le metriche di errore definite nella sezione 1.1.1 calcolate nella fase di validazione sia per il modello DSM che TSM sono riportate nella tabella I.28 e confermano il miglioramento nella previsione grazie all'introduzione del terzo coefficiente.

**Tab. I.27:** Statistiche riassuntive della distribuzione degli errori di previsione commessi dal modello a tripla stagionalità (TSM) applicato ai dati di validazione (gennaio 2013).

Media [MW]	Dev.Std. [MW]	Mediana [MW]	Min [MW]	Max [MW]
-0.04	1.16	0.2	-6.5	2.58



**Fig. I.40:** Assorbimento di potenza osservato e previsto durante il periodo di validazione, ossia le 744 ore di gennaio 2013. La linea nera rappresenta i valori osservati, la linea verde quelli previsti dal TSM.



**Fig. I.41:** (a) Istogramma di frequenza degli errori calcolati applicando il modello TSM ai 744 dati di validazione. (b) Grafico quantile-quantile (distribuzione normale ipotizzata) che descrive l'andamento degli errori di previsione del modello TSM applicato ai 744 dati di validazione. (c) Correlogramma degli errori di previsione del modello TSM applicato ai dati di validazione del gennaio 2013.

**Tab. I.28:** Metriche di errore MPE e CVE calcolate nella fase di validazione per i due diversi modelli.

Tipologia di modello	Set di dati	MPE	CVE
Doppia stagionalità	744 dati di validazione	27.9	0.322
Tripla stagionalità	744 dati di validazione	2.9	0.175

### 1.3.6 Discussione sui risultati ottenuti

In questa sezione è stato presentato un innovativo modello di decomposizione deterministica e lo stesso è stato applicato a una serie storica di consumo elettrico dovuto al trasporto pubblico nella città di Sofia (Bulgaria).

L'importanza della previsione del consumo elettrico è fortemente in relazione ai vantaggi sia per la società pubblica che per i consumatori principali attenti alla gestione d'impresa.

Il set di dati usato è costituito dal consumo elettrico orario dei tram e filobus di Sofia, valori misurati negli anni 2011, 2012 e 2013. I risultati dei test statistici di Ljung-Box e Box-Pierce aiuta a individuare una periodicità nella serie e ad escludere un andamento puramente casuale dei dati. Lo studio dei correlogrammi evidenzia il massimo della funzione di autocorrelazione e ci consente di scegliere la corretta frequenza da riprodurre. I test statistici Augmented Dickey-Fuller e Phillips-Perron hanno reso possibile escludere la presenza di radici unitarie nel processo generatore della serie storica e dunque di propendere per la stazionarietà dei dati.

I modelli usati in questa sezione per ricostruire l'andamento della serie sono costruiti con una componente di trend, stimato con una funzione parametrica, e una componente stagionale ottenuta tramite coefficienti moltiplicativi calcolati tramite metodi non parametrici. Questi coefficienti stagionali sono capaci di riprodurre le diverse frequenze osservate nella serie. In particolare sono stati presentati due modelli: un primo con due coefficienti stagionali (DSM) e un secondo che aggiunge un terzo fattore mensile (TSM).

Un'analisi preliminare è stata svolta sui dati di consumo misurati durante il 2011: in questa fase di calibrazione, i risultati del DSM e del TSM sono stati confrontati sia in termini grafici rispetto ai dati reali misurati sia mediante analisi dell'errore di previsione definito come differenza tra il valore misurato e quello previsto in un singolo periodo. È stato molto evidente il miglioramento ottenuto con l'implementazione del TSM e non trascurabile è stata la riduzione dell'autocorrelazione nel set di errori rispetto al caso del DSM.

Anche se i test statistici Lee-White-Granger e Teräsvirta-Lin-Granger eseguiti sui dati fanno propendere per il rifiuto dell'ipotesi nulla di linearità della serie, il modello TSM riesce a riprodurre molto bene l'andamento dei dati di calibrazione, sia in termini di trend generale che di periodicità.

Inoltre il TSM è stato testato su una serie estesa effettuando la calibrazione sui dati del 2011 più quelli del 2012. Come era atteso a causa della stazionarietà della serie, e dall'alto valore dei valori massimi di autocorrelazione, aggiungendo i dati del 2012 all'analisi, sono state osservate variazioni trascurabili nei coefficienti di stagionalità usati per riprodurre le prime due periodicità, giornaliere e settimanali ovvero di alta e media frequenza.

Invece il terzo coefficiente di bassa frequenza, che si discosta fortemente dal valore neutrale di uno nei vari mesi, ha beneficiato dell'allargamento del set di calibrazione e dunque di un migliore valutazione.

Infine le prestazioni previsionali del modello TSM sono state validate in un periodo di consumo elettrico non usato nelle fasi precedenti di calibrazione, ossia 744 ore di gennaio 2013.

Le buone prestazioni raggiunte sono state evidenziate dal confronto grafico, dal basso valore di media e deviazione standard dell'errore di previsione che inoltre appare normalmente distribuito e poco autocorrelato, dunque frutto di fluttuazione casuali e non di deficit sistematici. Sono stati riscontrati anche valori molto bassi delle metriche di errore MPE e CVE.

Oltre che per gli scopi previsionali mostrati, i coefficienti del modello possono essere usati per comprendere meglio l'andamento dei consumi in diverse stagioni e condizioni, sia da un punto di vista qualitativo che quantitativo. Ad esempio riguardo l'aumento dei consumi nei mesi invernali, la percentuale di assorbimento dovuta al sistema di riscaldamento può essere valutata mediante i coefficienti mensili al fine di valutare l'applicazione di una strategia di taglio del carico per ottenere un vantaggio nella gestione della rete elettrica della città.

**Modelli stocastici stagionali auto-  
regressivi a media mobile**



## **2.1 Confronto tra un modello deterministico di decomposizione e un modello ARIMA stagionale per l'analisi di serie storiche applicati alla previsione della rumorosità di un aeroporto**

La crescita della necessità di viaggi lontani, insieme alle frenetiche attività dilaganti che impongono spostamenti rapidi, si traducono in una crescita generale del traffico aereo sia su scala regionale che internazionale [51]. Anche se le compagnie aeree tendono ad adottare un limitato numero di grandi aeroporti in ogni nazione, altre strategie aziendali impongono di incrementare il numero di possibili destinazioni al fine di consentire di raggiungere tramite aereo un gran numero di destinazioni sia per finalità turistiche che di affari. Solitamente gli aeroporti delle grandi città e delle capitali sono posizionati fuori dall'abitato, in località con una densità molto bassa di costruzioni residenziali. Tuttavia le città più piccole possono avere aeroporti posizionati nelle immediate periferie con conseguenti problemi di impatto ambientale. Tra gli agenti nocivi da tenere in considerazione, una certa attenzione deve essere devoluta agli inquinanti dell'aria. Molti articoli in letteratura riguardano questo tema, ad esempio in [52] è presentato uno studio dettagliato sul contributo delle congestioni sulle strade intorno agli aeroporti statunitensi ai livelli locali di inquinamento e sulle contemporanee patologie dei residenti vicini all'aeroporto e sottovento. Gli autori hanno correlato i ritardi sulla rete dei grandi aeroporti sulla costa est degli Stati Uniti con la crescita delle congestioni sulle strade della California, il tutto collegato alla crescita dei livelli di inquinamento giornaliero intorno agli stessi aeroporti. Inoltre, in contemporanea alla crescita del monossido di carbonio dovuto al traffico aeroportuale, sono state osservate una crescita dei tassi di ospedalizzazione per patologie respiratorie e altre patologie correlate con conseguenziali accettazioni al pronto soccorso.

Un'altra importante conseguenza del traffico aereo e delle strutture aeroportuali è la rumorosità acustica. È ovvio che un aeroplano è una potente sorgente di rumorosità acustica, a causa delle turbine, dell'emissione aerodinamica, delle accelerazioni durante il decollo e l'atterraggio, del contatto tra pneumatici e asfalto della pista. È disponibile una vasta letteratura riguardante queste problematiche del rumore aeroportuale, ad esempio in [53] è proposta una tecnica per separare il rumore degli aerei da quello di fondo, per ricavare questa metodologia è stato analizzato un set di misurazioni sperimentali vicino all'aeroporto di Barcellona. In [54], usando una strumentazione microfónica direzionale, è stato proposto un metodo per stimare la direzione di arrivo della rumorosità degli aerei, risolvendo il problema delle riflessioni dal suolo.

In accordo alle tecniche presentate nel capitolo precedente nelle quali l'analisi delle serie storiche è stata svolta mediante tecniche di decomposizione deterministica di seguito verranno presentati due modelli differenti per l'analisi e la previsione di un set di misurazioni di rumorosità acustica. Il primo modello adottato è ancora basato sulla scomposizione della serie nelle sue componenti di trend, stagionalità e componente casuale: dunque può essere ascritto alle tecniche di decomposizione deterministica (DD-TSA). Il secondo modello costruito è di tipo stocastico e appartiene alla famiglia delle tecniche stagionali auto-regressive a media mobile (SARIMA). La serie storica studiata include 224 misurazioni del livello acustico equivalente acquisite in prossimità dell'aeroporto di Nizza (Francia), durante il periodo natalizio del 2000. La caratteristica più interessante del set di dati è la forte periodicità, insieme con il repentino cambiamento della media che si verifica la vigilia di natale. La stagionalità presente nella serie sarà utilmente sfruttata da entrambe le tipologie di modelli, mentre il cambio della media evidenzierà interessanti peculiarità delle due diverse tecniche.

È doveroso ribadire che le tecniche di analisi e previsione delle serie storiche sono largamente adottate in diversi contesti della fisica applicata e dell'ingegneria: è infatti molto comune che alcune variabili di interesse siano collezionate in maniera sequenziale nel tempo. Inoltre questa tipologia di analisi è largamente adottata in economia e finanza, discipline nelle quali vengono monitorati i tassi di interesse settimanali, i prezzi di chiusura dei titoli azionari, e vari indici di prezzo mensili. Nelle scienze mediche e biologiche possono essere monitorati vari parametri ad intervalli equi-spaziati nel tempo come ad esempio l'attività elettrica del cuore e del cervello ad intervalli di millisecondi [55,56]. Nell'ingegneria civile e nella geofisica una delle possibili applicazioni è il monitoraggio della periodicità nel verificarsi dei terremoti [57].

In questa sezione la serie storica analizzata è composta da osservazioni del livello acustico equivalente calcolate su intervalli di tempo orari, dunque dati equi-spaziati nel tempo. Inoltre si tratta ancora di una serie univariata: le informazioni estratte dai modelli derivano dalle osservazioni passate degli stessi dati. In generale lo scopo dell'analisi delle serie storiche è duplice: prima di tutto capire e modellare il meccanismo generatore dei valori osservati, il secondo obiettivo è la previsione dei valori futuri della serie basandosi sulle informazioni estratte dal passato. I metodi proposti di seguito si ribadisce che sono di due differenti tipologie: il modello DD-TSA considera l'assunzione teorica che i valori osservati sono generati da una funzione deterministica "disturbata" da fluttuazioni casuali che riproducono un "rumore bianco". Il secondo modello considera i valori assunti dalla serie come delle realizzazioni di un processo stocastico che nel caso specifico è del tipo auto-regressivo a media mobile. Entrambi i modelli sfruttano la forte caratterizzazione periodica della serie evidenziata mediante la massimizzazione della funzione di autocorrelazione.

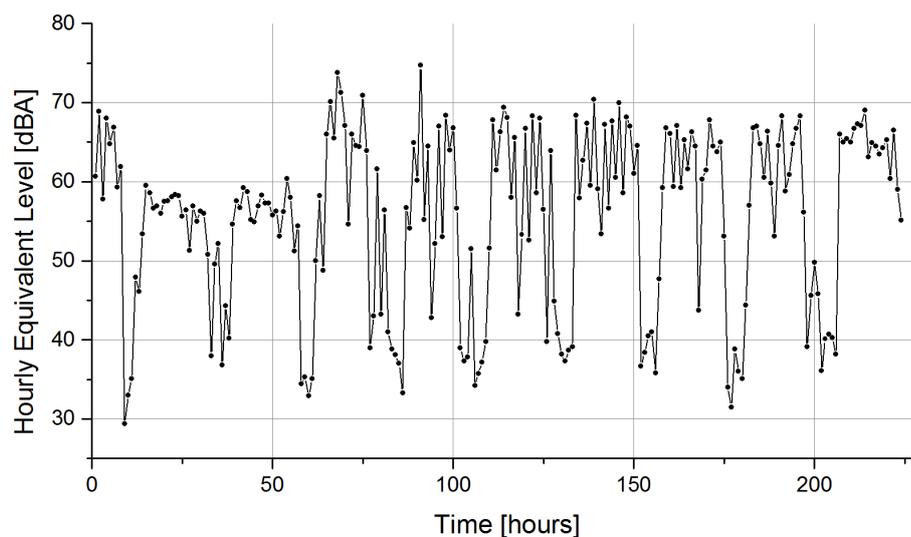
### *2.1.1 Analisi dei dati: aeroporto internazionale di Nizza*

Come riferito in precedenza il set di dati usato in questa sezione è composto da 224 livelli equivalenti orari di rumore, misurati in prossimità dell'aeroporto di Nizza (Francia), durante il periodo natalizio del 2000. Le statistiche riassuntive dei dati sono mostrate nella tabella II.1. L'alto valore della deviazione standard mostra che è presente una grande dispersione dei dati come evidenziato anche dalla notevole distanza tra il valore massimo e minimo misurati. Questa deve considerarsi una significativa differenza rispetto alle serie storiche di rumore acustico analizzate nel capitolo precedente nel quale la sequenza di dati era molto più stabile. I valori degli indici di asimmetria e curtosi suggeriscono una distribuzione normale dei dati, una caratteristica importante per l'applicazione dei modelli stocastici.

Nella figura II.1 il grafico dei dati misurati (l'intera serie storica studiata) è presentata. La caratterizzazione stagionale è evidente, come lo è anche la differenza tra i valori misurati durante il giorno e durante la notte (periodo di attività e chiusura dell'aeroporto). È facilmente notabile anche una forte variazione del valore della media tra i periodi 60 e 70. Questo intervallo di tempo corrisponde all'inizio della vigilia di natale. È facile aspettarsi un aumento nella numerosità dei voli, delle persone che raggiungono l'aeroporto, dei taxi e delle autovetture che circolano nella zona dell'aeroporto, il tutto a causa dell'inizio del periodo delle vacanze in una località turistica come Nizza. Questi fattori si traducono anche in un aumento dei livelli di rumorosità misurati e in una variazione della media della serie storica. Anche se queste peculiarità rendono la serie non stazionaria, l'andamento periodico e il passo di stagionalità restano preservati.

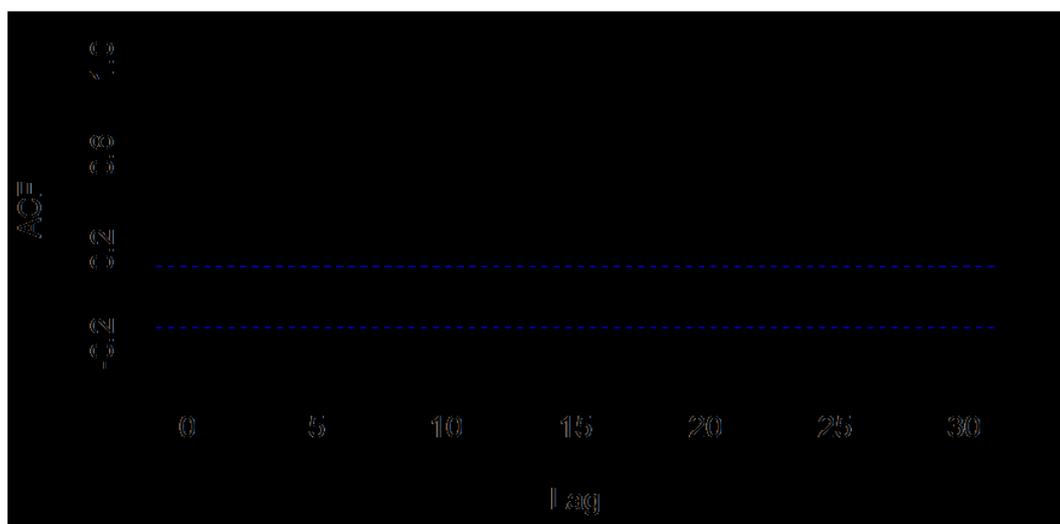
**Tab. II.3:** Statistiche riassuntive del livello equivalente misurato durante i primi 224 giorni del set di dati di calibrazione.

Media [dBA]	Dev. Std. [dBA]	Mediana [dBA]	Min [dBA]	Max [dBA]	skew	kurt
55.4	11.1	57.9	29.4	74.7	-0.59	-0.85

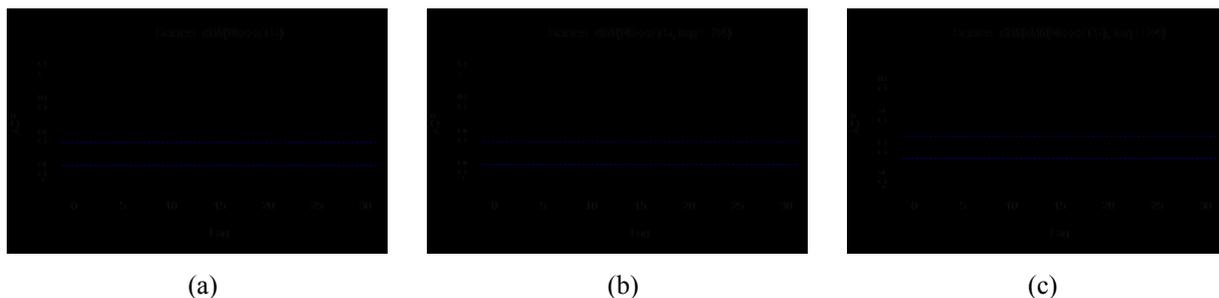


**Fig. II.1:** Livelli orari equivalenti osservati durante i 224 periodi di calibrazione.

Guardando la figura II.2 può essere desunto che il più alto livello dell'autocorrelazione nei dati si è ottenuto per un ritardo pari a 24 periodi, ossia la periodicità della serie è esattamente di un giorno, come era lecito aspettarsi.



**Fig. II.2:** Correlogramma dei 224 dati della serie.



**Fig. II.3:** Correlogramma delle differenze eseguite sui 224 dati della serie: (a) a sinistra la prima differenza; (b) al centro le differenze di ordine 24 (ritardo stagionale); (c) correlogramma della doppia differenziazione di ordine uno e di ordine 24.

### 2.1.2 Richiamo ai modelli di decomposizione deterministici

Il primo modello adottato appartiene alla classe di quelli deterministici ampiamente descritti nel capitolo precedente, dunque è basato sull'assunzione teorica che la serie storica osservata è generata da un polinomio deterministico composto dalla moltiplicazione del trend e da un fattore stagionale.

È richiamata di seguito l'assunzione teorica di questo modello DD-TSA basata sull'idea che un'osservazione della serie  $Y_t$ , in un qualsiasi periodo  $t$ , è data da:

$$Y_t = T_t \bar{S}_i + e_t, \quad (\text{II.1})$$

nella quale ancora una volta  $T_t$  è il trend,  $\bar{S}_i$  è il coefficiente stagionale (la cui definizione è richiamata di seguito) e  $e_t$  è la componente irregolare, non prevedibile deterministicamente, la quale si assume essere distribuita secondo una normale. La componente di trend in questa applicazione è stata calcolata con l'ausilio di una regressione lineare calcolata sui dati osservati. Si ricorda anche che l'indice del periodo  $t$  varia da 1 a  $n$ , il numero totale dei periodi. Nel caso presentato  $n$  è uguale a 224 ore, mentre  $i$  varia da 1 a  $k$ , il coefficiente di ritardo, assumendo che l'effetto stagionale è periodico di periodo  $k = 24$ . In altre parole, assumendo una periodicità giornaliera,  $i$  varierà tra 1 a 24, e rappresenterà ciascuna ora del giorno (01:00, 02:00, etc.).

La formula per  $\hat{Y}_t$ , la previsione fornita dal modello, è data dalla moltiplicazione tra il trend e la stagionalità:

$$\hat{Y}_t = (b_0 + b_1 t) \bar{S}_i, \quad (\text{II.2})$$

La stima dei valori futuri ancora una volta è data dalla combinazione del trend, cioè l'andamento di lungo periodo delle misurazioni, moltiplicato per un fattore stagionale, ossia una correzione dovuta all'andamento dello specifico periodo.

Una media mobile è adottata per rimuovere la caratterizzazione periodica della serie osservata. In particolare è stata adottata una media mobile centrata di ampiezza pari a 24 ore. L'effetto stagionale  $S_t$  ad un dato periodo  $t$ , è ottenuto mediante il rapporto tra il valore reale  $Y_t$  e il valore della media mobile  $M_t$  come mostrato in dettaglio nella formula I.5. Il fattore stagionale  $\bar{S}_i$ , valutato su tutti i periodi omologhi, è stato stimato mediando gli effetti stagionali, in accordo alla formula I.6.

### 2.1.3 Modelli ARIMA stagionali

A causa della forte caratterizzazione stagionale mostrata dai dati una scelta logica è l'adozione di modello stagionale auto-regressivo a media mobile (SARIMA) per descrivere la funzione generatrice di questa serie storica. In generale i polinomi lineari classe SARIMA sono modelli stagionali stocastici costruiti per analizzare e prevedere una sequenza di dati studiata. Punti forti di questo tipo di modellazione sono la possibilità di prevedere i valori osservati con un ridotto numero di variabili in ingresso, seguendo il principio della parsimonia dei parametri, e la possibilità di estendere la previsione ad un orizzonte lungo.

Il modello stocastico lineare adottato più precisamente appartiene alla specifica tipologia degli ARIMA moltiplicativi stagionali (auto-regressivi integrati a media mobile). Un modello moltiplicativo stagionale,  $ARMA(p,q) \times (P,Q)_s$  con passo di stagionalità  $s$ , è definito con un polinomio AR caratteristico  $\phi(x)\Phi(x)$  e un polinomio caratteristico MA  $\theta(x)\Theta(x)$ , [58], con:

$$\begin{cases} \phi(x) = 1 - \phi_1 x - \phi_2 x^2 - \dots - \phi_p x^p \\ \Phi(x) = 1 - \Phi_1 x^s - \Phi_2 x^{2s} - \dots - \Phi_P x^{Ps} \end{cases}, \quad (II.3)$$

$$\begin{cases} \theta(x) = 1 - \theta_1 x - \theta_2 x^2 - \dots - \theta_q x^q \\ \Theta(x) = 1 - \Theta_1 x^s - \Theta_2 x^{2s} - \dots - \Theta_Q x^{Qs} \end{cases}, \quad (II.4)$$

Il modello ARMA diventa  $ARIMA(p,d,q) \times (P,D,Q)_s$  dopo che la  $d$ -esima differenziazione dei dati è stata eseguita. Queste differenziazioni successive hanno come scopo principale quello di ottenere la stazionarietà della serie.

Questi specifici modelli combinano le strategie dei modelli stagionali e non-stagionali ARMA sviluppando una funzione parsimoniosa (ossia con un ridotto numero di parametri) che sfrutta informazioni dai dati con ritardo stagionale ma anche dai dati più vicini temporalmente a quelli da prevedere. La differenza più importante tra questi modelli e quelli deterministici, ampiamente descritti e applicati nel capitolo precedente, è che i parametri qui evolvono nel tempo, seguendo i cambiamenti del processo, mentre nei DD-TSA i coefficienti sono costanti e non riescono ad apprezzare variazioni nel tempo del processo studiato. Dunque i SARIMA sono capaci di adattarsi rapidamente a possibili variazioni nell'andamento della serie, ma pagano questa qualità con l'aver un orizzonte previsionale notevolmente ridotto rispetto ai DD-TSA. Questo tipo di strategia dipende

fortemente dai dati recenti (vicini al periodo da prevedere), sia nella fase di calibrazione dei parametri che in quella vera e propria di previsione.

#### 2.1.4 Metodi per la valutazione dell'accuratezza dei modelli

La componente irregolare presente nella serie ( $e_t$ ), ossia la fluttuazione casuale non prevedibile, può essere studiata mediante l'analisi dei residui riscontrati durante la fase di calibrazione del processo di modellazione, cioè ragionando su valori reali noti. Si ricorda che i residui sono definiti come il valore reale meno la previsione, differenza calcolata per ogni periodo  $t$ , in accordo con la formula I.8.

L'assunzione generale è che il termine di irregolarità è normalmente distribuito, la sua media è zero e coincide con la moda, ovvero il valore più probabile.

I modelli di analisi delle serie storiche possono essere calibrati (fase di stima dei parametri e dei coefficienti) su di un certo intervallo di dati. Nel prosieguo sarà presentata una comparazione tra i due differenti modelli, calibrati sugli stessi dati.

Al fine di valutare l'accuratezza dei modelli, la caratterizzazione statistica dei residui è stata studiata. Sarà presentato l'istogramma di frequenza degli errori insieme ai principali indicatori statistici; saranno mostrati gli indici di asimmetria e curtosi per valutare la normalità della distribuzione dei residui. Anche il diagramma quantile-quantile e il correlogramma per i residui dei due modelli saranno analizzati.

Una misura delle prestazioni di un modello previsionale può essere ottenuta dal "Mean Absolute Scaled Error" (MASE). Questa viene considerata un'ottima misura quantitativa dell'accuratezza di un modello [59]; questa metrica è adottata anche se la serie storica studiata presenta valori vicini allo zero o negativi, inoltre il MASE fornisce indicazioni affidabili anche se si confrontano modelli applicati a dati con ordini di grandezza molto diversi. Il MASE è calcolato in accordo alla formula seguente:

$$\text{MASE} = \frac{1}{n} \sum_{t=1}^n \frac{|e_t|}{\frac{1}{n-k} \sum_{i=k+1}^n |Y_i - Y_{i-k}|}, \quad (\text{II.5})$$

Il MASE in questo elaborato è calcolato usando al denominatore un modello base di riferimento come in [60], ossia il valore della serie  $k$  periodi prima di  $t$ , assumendo che la serie fortemente periodica possa replicare al periodo  $t$  il valore osservato al tempo  $t-k$ .

#### 2.1.5 Dettagli e risultati del modello DD-TSA

Il modello DD-TSA descritto è stato calibrato sul set di dati studiato; i 24 coefficienti stagionali, uno per ogni ora del giorno, sono presentati nella tabella II.2, insieme ai parametri del trend, ottenuti con la regressione lineare mostrati in tabella II.3.

Per quanto riguarda i coefficienti stagionali è doveroso sottolineare che il coefficiente del primo periodo osservato corrisponde alle 17:00 dato che in quest'ora è stata misurato il primo livello equivalente del set di dati di calibrazione. Si può notare che i coefficienti da  $\bar{S}_8$  a  $\bar{S}_{14}$  (relativi alle ore 24:00 e alle 18:00) sono più bassi di 1. Questi coefficienti infatti corrispondono al periodo notturno e dunque, moltiplicati per il trend generale, riducono la rumorosità prevista come è lecito attendersi.

Per quanto riguarda i valori della tabella II.3, si può concludere che la pendenza dei dati è leggermente crescente nel periodo di osservazione, il valore dell'intercetta è simile a quello del valor medio dei dati riportato in tabella II.1.

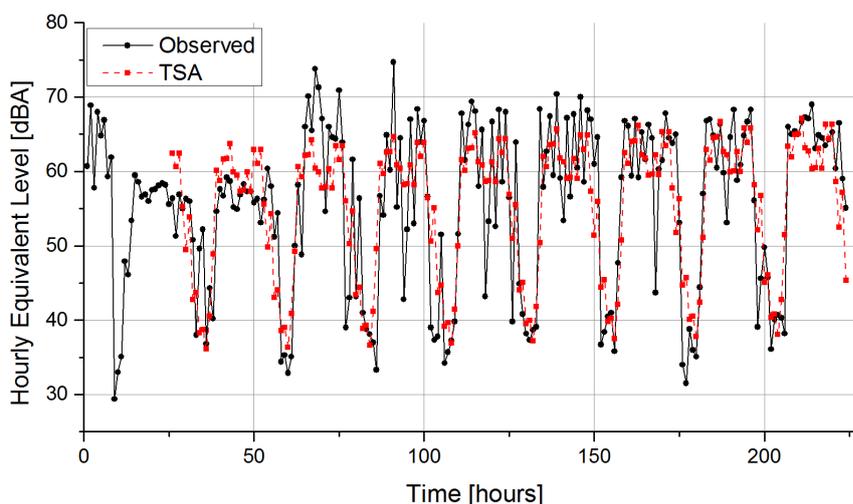
Il risultato finale dell'applicazione del modello DD-TSA è riportato in figura II.4 (linea rossa tratteggiata) con il raffronto dei dati reali rappresentati mediante la linea continua nera. La curva della previsione approssima bene i valori osservati nella seconda parte del grafico, cioè dopo il cambio nella media. La curva della previsione comincia dopo 24 dati al fine di rendere possibile una comparazione con il modello SARIMA che comincia a produrre previsioni a partire dal periodo  $k+1$ .

**Tab. II.2:** Coefficienti stagionali del modello DD-TSA, stimati durante la calibrazione sui 224 periodi, uno per ognuna delle 24 ore del giorno. Il primo coefficiente corrisponde alle 17:00 e a seguire gli altri per le successive 24 ore.

$\bar{S}_1$	$\bar{S}_2$	$\bar{S}_3$	$\bar{S}_4$	$\bar{S}_5$	$\bar{S}_6$	$\bar{S}_7$	$\bar{S}_8$	$\bar{S}_9$	$\bar{S}_{10}$	$\bar{S}_{11}$	$\bar{S}_{12}$
1.060	1.164	1.1299	1.163	1.027	0.921	1.002	0.795	0.813	0.712	0.720	0.671
$\bar{S}_{13}$	$\bar{S}_{14}$	$\bar{S}_{15}$	$\bar{S}_{16}$	$\bar{S}_{17}$	$\bar{S}_{18}$	$\bar{S}_{19}$	$\bar{S}_{20}$	$\bar{S}_{21}$	$\bar{S}_{22}$	$\bar{S}_{23}$	$\bar{S}_{24}$
0.753	0.907	1.116	1.091	1.143	1.144	1.181	1.110	1.1027	1.061	1.063	1.108

**Tab. II.3:** Parametri del trend per il modello DD-TSA stimati sui 224 periodi di calibrazione:  $b_0$  e  $b_1$  sono rispettivamente l'intercetta e la pendenza.

	$b_0$ [dBA]	$b_1$ [dBA/hour]
Parametri del trend	53.2249934	0.017276496



**Fig. II.4:** Confronto tra i 224 dati di calibrazione osservati (linea nera continua) e i livelli previsti nello stesso periodo dal modello DD-TSA (linea rossa tratteggiata).

### 2.1.6 Dettagli e risultati del modello SARIMA

L'ARIMA stagionale implementato in questa applicazione è strutturato su di una periodicità di 24 ore ( $s = 24$ ) e non include componenti di auto-regressione; inoltre effettua inferenza sui dati con una doppia differenziazione: sia di ordine uno che di ordine stagionale. Pertanto il modello scelto è un SARIMA  $(0,1,1) \times (0,1,1)_{24}$ , che sviluppato per esteso prevede valori osservati e previsti forniti rispettivamente dalle formule:

$$Y_t = Y_{t-1} + Y_{t-24} + Y_{t-25} + e_t - \theta e_{t-1} - \Theta e_{t-24} + \theta \Theta e_{t-25}, \quad (\text{II.6})$$

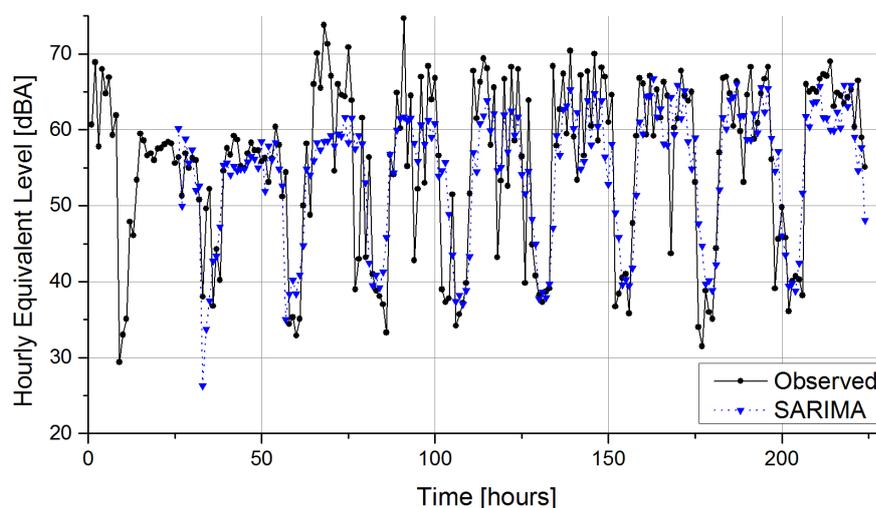
$$\hat{Y}_{t+1} = Y_t + Y_{t-23} + Y_{t-24} - \theta e_t - \Theta e_{t-23} + \theta \Theta e_{t-24}. \quad (\text{II.7})$$

La stima dei due parametri è stata ottenuta in ambiente *R* applicando la massimizzazione della funzione di verosimiglianza (likelihood). I risultati sono mostrati in tabella II.4.

**Tab. II.4:** Valori stimati dei coefficienti del modello SARIMA  $(0,1,1) \times (0,1,1)_{24}$ .

Coefficienti	Valore Stimato	Errore Standard
MA1( $\theta$ )	-0.9752	0.0626
SMA1( $\Theta$ )	-0.9969	0.6184
Log likelihood = -700.38; AIC = 1406.76		

Il risultato finale dell'applicazione del SARIMA è riportato nella figura II.5 (linea blu), confrontato con la serie realmente osservata (linea nera). Può essere notato che questo modello segue meglio del precedente le variazioni di breve periodo nei dati. Questo è dovuto alla variazione nel tempo della previsione molto rapida che consente al modello di adattarsi ai dati più recenti.



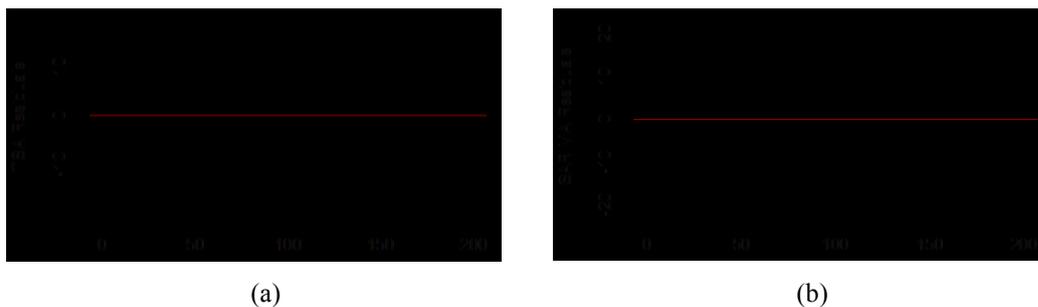
**Fig. II.5:** Confronto tra i 224 dati di calibrazione osservati (linea nera continua) e i livelli previsti nello stesso periodo dal modello SARIMA  $(0,1,1) \times (0,1,1)_{24}$  (linea blue).

### 2.1.7 Diagnostica dei modelli e analisi dei residui

La tecnica più usata per verificare quantitativamente le prestazioni di un modello previsionale è l'analisi dei residui. I residui sono definiti in accordo con la formula I.8, come la differenza tra i valori osservati della serie e quelli previsti dal modello preso in esame. È utile notare che un residuo positivo denota una sottostima della misurazione reale, mentre uno negativo dimostra che il modello ha sovrastimato il valore reale in quel periodo.

I grafici dei residui in funzione del tempo per i modelli DD-TSA e SARIMA sono riportati nella figura II.6. nella tabella II.5 sono riportate le statistiche principali: è evidente che il modello DD-TSA dimostra migliori prestazioni rispetto al SARIMA. Sia la media che la deviazione standard degli errori sono più basse per il modello deterministico anche se la precedente comparazione grafica non esaltava questa differenza. Osservando le figure II.4 e II.5 e concentrandosi sui periodi che vanno approssimativamente dal 25 al 90, può essere colta la differenza principale nella previsione dei due modelli. Quando si verifica la brusca variazione nella media, il SARIMA impiega circa un giorno (24 periodi) per apprendere la variazione nella serie e per adeguare la previsione al nuovo andamento dei dati. Al contrario il DD-TSA fornisce una previsione molto stabile in media e dunque sovrastima nel primo intervallo temporale e poi sottostima quando si verifica l'incremento della rumorosità. Queste caratteristiche sono evidenziate anche dal basso valore dell'MPE per il modello SARIMA se confrontato con lo stesso indicatore del modello deterministico: MPE considera un errore percentuale dunque penalizza i modelli che a parità di errore assoluto commettono questo in periodi di tempo caratterizzati da valori della serie più bassi.

Le figure II.7 e II.8 riportano il correlogramma dei residui, l'istogramma di frequenza e il diagramma quantile-quantile. Questi grafici nel loro complesso provano le buone prestazioni previsionali dei due modelli proposti e confermano l'assunzione teorica di una distribuzione normale per i residui.



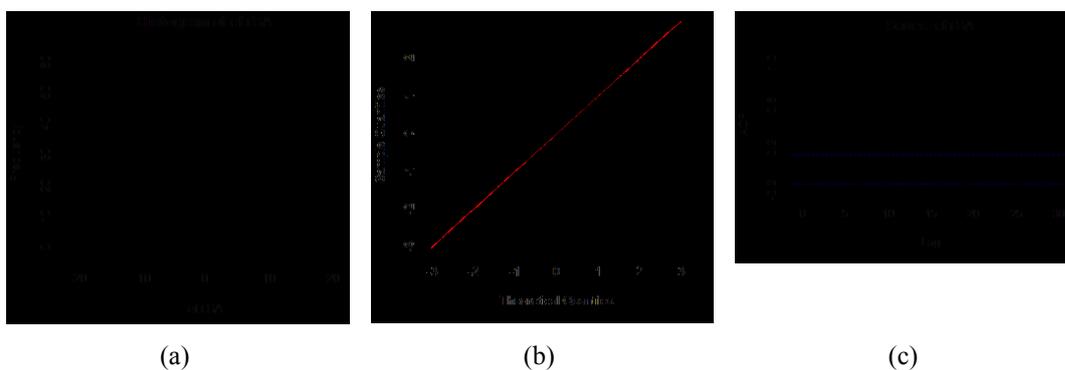
**Fig. II.6:** (a) Grafico dei residui ottenuti usando il modello DD-TSA sui 224 dati di calibrazione. L'asse orizzontale è in ore, l'asse verticale è in dBA. (b) Grafico dei residui ottenuti usando il modello SARIMA sui 224 dati di calibrazione.

**Tab. II.5:** Statistiche riassuntive della distribuzione degli errori valutati sia nella fase di calibrazione utilizzando i due modelli.

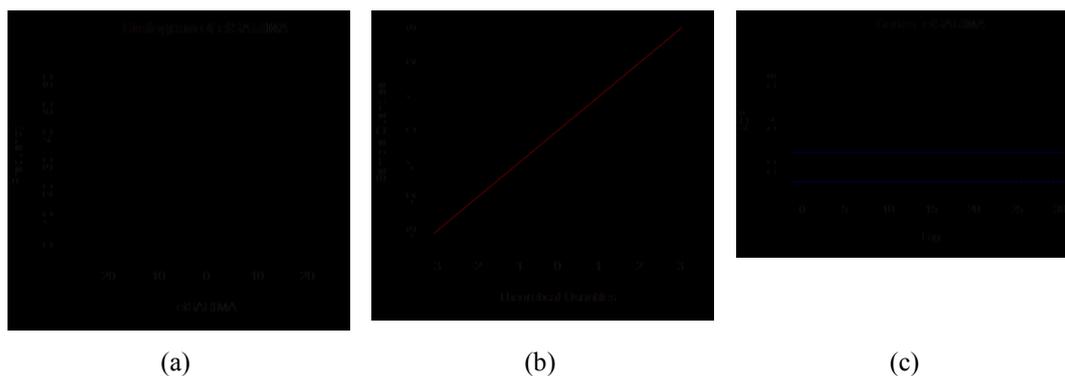
Modello	Media [dBA]	Dev.Std. [dBA]	Mediana [dBA]	Min [dBA]	Max [dBA]	skew	kurt
DD-TSA	0.06	6.53	0.42	-18.5	18.0	-0.28	0.25
SARIMA	0.98	7.03	1.33	-20.6	21.35	-0.38	0.75

**Tab. II.6:** Valori delle metriche di errore MPE, CVE e MASE calcolati nella fase di calibrazione per i due differenti modelli.

Tipologia di modello	MPE	CVE	MASE
DD-TSA	-1.559	0.118	0.750
SARIMA	-0.102	0.128	0.795



**Fig. II.7:** (a) Istogramma di frequenza degli errori calcolati applicando il modello DD-TSA ai 224 dati di calibrazione. (b) Grafico quantile-quantile (distribuzione normale ipotizzata) che descrive l'andamento degli errori del DD-TSA. (c) Correlogramma degli errori di previsione del DD-TSA.



**Fig. II.8:** (a) Istogramma di frequenza degli errori calcolati applicando il modello SARIMA ai 224 dati di calibrazione. (b) Grafico quantile-quantile (distribuzione normale ipotizzata) che descrive l'andamento degli errori del SARIMA. (c) Correlogramma degli errori di previsione del SARIMA.

### 2.1.8 Discussione sui risultati ottenuti

In questo paragrafo, l'attenzione è stata focalizzata sullo studio e la previsione del livello acustico nei pressi di un aeroporto. È stata svolta un'analisi della serie storica dei livelli acustici equivalenti orari, rilevati in prossimità dell'aeroporto internazionale di Nizza (Francia). Diverse tecniche statistiche sono state applicate a queste misurazioni per evidenziare le caratteristiche peculiari e per attuare la migliore scelta dei modelli predittivi.

Sono stati implementati due differenti tecniche per la modellazione di una serie storica. Inizialmente è stato sfruttato un modello di decomposizione deterministica (DD-TSA) basato sull'assunzione che il livello acustico misurato è stato generato da una funzione costituita dalla moltiplicazione del trend per dei fattori di correzione stagionali. A questi, in maniera additiva, si aggiunge una componente di fluttuazione casuale non prevedibile e distribuita normalmente con media nulla. Il trend costituisce l'andamento di lungo periodo ed è stato calcolato con una regressione lineare sui dati osservati: la funzione scelta, di tipo linea retta, è molto adatta quando si vogliono ottenere orizzonti di previsione lunghi dato che non soffre eccessivamente di *overfitting* sui dati usati per la stima dei coefficienti, un comportamento diverso hanno funzioni polinomiali di grado elevato adatte quando lo scopo della modellazione è la ricostruzione di dati mancanti. I fattori di stagionalità descrivono la periodicità osservata nella serie e sono calcolati mediante una tecnica di statistica non parametrica.

La seconda tecnica adottata si basa sull'assunzione che le singole osservazioni della serie sono la realizzazione di una variabile casuale: viene implementato un modello stagionale auto-regressivo a media mobile (SARIMA).

Entrambi i modelli sfruttano il marcato comportamento periodico evidenziato nella serie. Tale serie storica è costituita da 224 misurazioni, e, grazie all'applicazione di alcune procedure statistiche, la presenza di variazioni periodiche è stata evidenziata. Entrambe le tecniche usate per modellare i dati considerano una periodicità giornaliera, evidenziata dalla massimizzazione della funzione di autocorrelazione in corrispondenza di un ritardo pari a 24 ore.

È stato mostrato un confronto grafico dei due modelli diagrammando le previsioni insieme alle 224 misure reali; inoltre è stato svolto un dettagliato studio dei residui (differenza tra i valori reali e le previsioni) per ottenere un confronto quantitativo tra le

prestazioni previsionali delle due tecniche. Anche se le buone prestazioni predittive delle due strategie adottate sono simili, il DD-TSA si è caratterizzato per un valore della media dei residui più prossimo allo zero e per una deviazione standard degli stessi più bassa. Inoltre anche l'autocorrelazione presente negli errori del DD-TSA è inferiore rispetto a quella riscontrata per il SARIMA.

Gli indici di asimmetria e curtosi per i residui di entrambi i modelli, sono vicini allo zero. Inoltre, istogrammi e QQ-plot confermano l'ipotesi di distribuzione normale per gli errori. Questa è una prova delle buone capacità predittive delle tecniche proposte.

Per quanto riguarda le metriche di errore, la CVE ha dato risultati migliori per il modello DD-TSA, mentre l'MPE è più basso (dunque migliore) per il SARIMA. Questo accade perché il modello SARIMA ha dato previsioni peggiori nei periodi con livelli di rumorosità più elevati, con un conseguente errore percentuale più basso, anche se l'errore medio è più alto. Guardando il MASE si può affermare che i due modelli adottati forniscono previsioni migliori, in media, rispetto al modello stagionale basilare fondato sull'ipotesi che la previsione di riferimento (più semplice da ottenere) al periodo  $t$  è uguale al valore osservato all'ora  $t-24$ . Le buone capacità predittive sia di DD-TSA che di SARIMA sono altresì confermate dal fatto che il valore del MASE è inferiore all'unità.

Infine, si può concludere che l'obiettivo di ottenere un modello previsionale affidabile per il livello di rumorosità acustica in prossimità di insediamenti aeroportuali è pienamente raggiunto per mezzo dell'analisi delle serie storiche, sia basata su tecniche di tipo deterministico (con un più ampio orizzonte predittivo, ma con una previsione molto statica nel tempo) sia del tipo stocastico SARIMA (con previsioni più rapide ad adeguarsi a variazioni nella serie ma con un più breve orizzonte).

## 2.2 Integrazione di metodi ARIMA e modellazione software per la previsione della velocità del vento e la realizzazione di mappe di rumorosità in un parco eolico

Le metodologie per la produzione di energia nell'ultimo secolo sono state al centro di un combattuto dibattito scientifico. Infatti la crescita della popolazione mondiale di uomini insieme al miglioramento delle condizioni socio-economiche di questi ultimi sono stati fattori fortemente correlati all'incremento della richiesta di energia. Tuttavia nello stesso periodo si è registrato un costante aumento delle temperature medie della biosfera, probabilmente legato all'uso massiccio di centrali termoelettriche alimentate con combustibili fossili e all'utilizzo di questi ultimi nelle macchine adibite al trasporto di uomini e merci. La combustione di gas e derivati del petrolio, per quanto ottimizzata, nonché l'energia liberata dal carbone, sono connesse al rilascio in atmosfera di gas serra; per approfondire questi temi energetici di interesse strategico si rimanda a "*Effetti indesiderati del rilascio di gas serra in atmosfera dovuto ad attività antropiche*", di Sergio De Filippo e Carmine Tepedino (<http://www.ftnews.it/articolo.asp?cod=743>), e a [30] degli stessi autori. Per affrontare questo problema, nei paesi industrializzati più progrediti, si è cercato di incentivare l'uso di fonti energetiche alternative, allo stato attuale delle conoscenze meno dannose per l'ecosistema che accoglie la vita della specie umana. Ci si riferisce in particolare alla produzione elettrica mediante effetto fotovoltaico o tramite l'installazione di aerogeneratori. Altre tecnologie altrettanto valide per una produzione energetica ad impatto ridotto sono state meno incentivate per ragioni che sarebbe difficile affrontare in maniera esaustiva in questo contesto, ci si riferisce in particolare alla generazione energetica mediante solare termico e mediante reazioni nucleari.

In questo scenario complesso in Italia e in altre importanti nazioni industrializzate si è assistito ad un rapido proliferare dell'installazione di aerogeneratori. L'energia del vento nei secoli è stata sfruttata per diversi scopi, ma solo di recente le turbine a vento sono state realizzate e diffusamente installate al fine specifico di produrre energia elettrica.

In accordo al rapporto 2009 del *Global Wind Energy Council*, alla fine del 2008 nel mondo era installata approssimativamente potenza per 120800 MW derivante da turbine eoliche [61]. Ma alla fine del 2015 la nuova potenza eolica installata nel mondo aveva raggiunto i 432419 MW [62]. Solo durante il 2015 in Europa sono stati installati 12800 MW di potenza eolica, una crescita del 6.3% rispetto al 2014.

Questa crescita così rapida implica però anche l'aggravarsi di notevoli problemi legati agli impianti eolici, sia in termini di negativo impatto ambientale nei pressi delle turbine, sia in termini di effetti negativi sulle reti elettriche non sempre adeguate a reggere una tale crescita di questi particolari generatori. Tra gli effetti nocivi sui quali ci sofferma in questa trattazione ci sono sicuramente i disturbi dovuti all'eccessiva rumorosità di queste macchine. La crescita dei livelli di rumorosità è solitamente riferita a isolati ricevitori sensibili poiché le turbine sono generalmente montate nelle zone di campagna o in zone collinari e montuose che circondano le città. Per queste ragioni spesso una accurata indagine della rumorosità non è eseguita prima dell'installazione dell'impianto causando procedimenti legali iniziati dagli abitanti delle zone interessate che subiscono il fastidio.

Una trattazione degli effetti nocivi di alti livelli di rumorosità sulla salute dell'uomo si può trovare in [63]. In letteratura si possono trovare molti studi che riguardano il problema della rumorosità degli aerogeneratori; uno degli obiettivi principali è quello di aiutare i decisori politici e i proprietari degli impianti di generazione nella scelta del sito, lo strumento utilizzato è quello previsionale volto a prevedere i diversi livelli di rumorosità a seconda della configurazione scelta per il parco eolico. Persson Wayne

e Öhrström [64] hanno proposto uno studio sperimentale al fine di supportare l'ipotesi che differenti proprietà della percezione umana del campo acustico possono essere correlate non solo alle condizioni operative del parco eolico, ma anche ad una personale sensibilità a queste emissioni delle turbine a vento.

Un importante risultato di questo esperimento, che consiste nel registrare e confrontare il rumore prodotto da cinque turbine in termini di diversa percezione di fastidio, è stato che le diverse turbine fornivano una differente sensazione di disturbo anche se il livello equivalente SPL, ponderato con curva *A*, era identico. Questa valutazione del suono soggettiva può essere molto rilevante per la percezione del fastidio specialmente in presenza di un rumore di fondo particolarmente basso. Ulteriori studi rafforzano queste conclusioni e suggeriscono che le soggettive caratteristiche del suono descritte come *lapping*, *swishing* e *whistling* sono responsabili delle differenze nelle percezioni della fastidiosità [65]. In [66,67], sono state implementate delle semplici modellazioni analitiche, capaci di fornire la propagazione dell'intensità del livello acustico come funzione della distanza orizzontale dalla torre, riscontrando una funzione Lorenziana, con il livello massimo in corrispondenza della torre (minima distanza sorgente ricevitore) e un punto di flesso. Nello stesso contesto sono state tracciate anche delle mappe di rumorosità di un parco eolico installato nel comune di Postiglione (Salerno, Italia), evidenziando alcune delle peculiarità dell'area studiata. Questo tipo di mappature acustiche sono state utilizzate con successo anche in altri contesti, come alcuni relativi ad infrastrutture di trasporto (vedere ad esempio [68-72]).

Nel prosieguo si è studiata l'emissione acustica di un parco eolico in Italia partendo dalla realizzazione di un modello di analisi delle serie storiche volto a descrivere l'andamento della velocità del vento nella zona di interesse: infatti l'emissione acustica di un aerogeneratore è strettamente legata alla velocità di rotazione della pala eolica e delle macchine collegate al suo asse. La modellazione adottata fornisce informazioni interessanti sul campo acustico e la propagazione della rumorosità in una zona di campagna. Inoltre, si è tenuta in considerazione la direttività della sorgente che è stata implementata nel software per la realizzazione delle mappature acustiche, dando interessanti risultati e mappature più realistiche.

Il parametro principale che guida la previsione è la velocità del vento. Questo valore, infatti, determina il livello di potenza della turbina (sorgente) e influenza le emissioni del parco eolico. Quando non è possibile misurare questo parametro o quando il parco eolico è ancora in fase di progettazione, è necessario un modello di previsione della velocità del vento. I modelli deterministici non sono sempre sufficienti per descrivere il comportamento di fenomeni altamente variabili come il vento. Per quanto riguarda la previsione di velocità del vento, la letteratura presenta diversi modelli (per esempio [73-76]). In questo paragrafo, per avere previsioni affidabili del vento, è stato implementato un modello lineare stocastico, in base all'analisi di una serie storica univariata relativa alla velocità oraria media del vento nella regione di interesse. Questo modello, della stessa classe SARIMA usata nella sezione precedente, fornirà i valori di input per la mappatura acustica realizzata grazie ad uno specifico programma. Questa "catena previsionale" può essere adottata per realizzare mappe acustiche per parchi eolici, avendo come ingresso fondamentalmente solo la serie temporale della velocità del vento, la geometria e le caratteristiche della zona in esame. Naturalmente, tale tecnica può essere implementata sia su impianti eolici già esistenti per valutarne l'impatto acustico sugli edifici circostanti, sia per progettare il miglior posizionamento di nuove turbine minimizzando il fastidio per i ricevitori sensibili della zona. Per una dettagliata descrizione delle fonti di rumorosità in un aerogeneratore si rimanda a [77].

### 2.2.1 Previsione della velocità del vento mediante un modello ARIMA

In questa sezione un modello ARIMA stagionale è stato sviluppato per prevedere la velocità del vento. Dato che questo parametro è un dato essenziale per le tracciature delle mappe di rumorosità, più la previsione sarà precisa più efficace sarà la stima della rumorosità stessa.

Per la calibrazione del modello una serie di dati della velocità del vento nell'area del parco eolico è necessaria. Ma a causa dell'assenza di una stazione meteorologica nella zona con dati accessibili, la modellazione è stata implementata sfruttando acquisizioni rese disponibili su piattaforma web [79]. Da questo sito internet sono stati scaricati dati della media oraria della velocità del vento relativi ad una settimana (dalle 13:00 del 21 luglio alle 3:00 del 28 luglio, ossia 159 dati). Per il fatto che queste misurazioni erano fornite in km/h e all'altezza del suolo sono stati convertiti in m/s e trasformati nel valore a 65 metri d'altezza, ovvero l'altezza dell'asse delle pale eoliche montate nell'impianto. La trasformazione dei dati causata dall'altezza di interesse è stata effettuata in accordo alla legge di potenza della velocità del vento [80]:

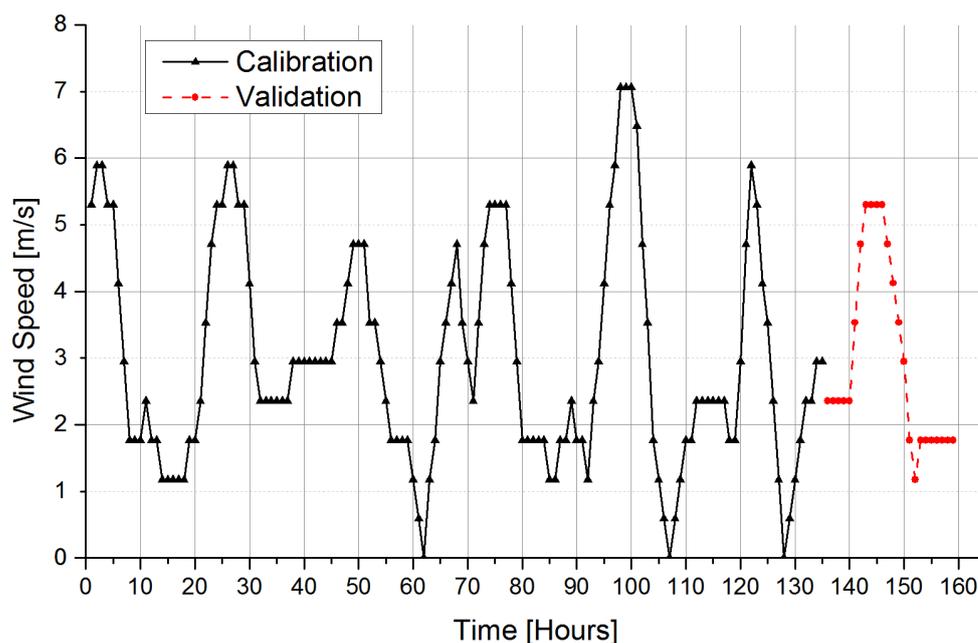
$$u = u_r \left( \frac{z}{z_r} \right)^\alpha . \quad (\text{II.8})$$

Nella quale  $u$  è la velocità del vento all'altezza di interesse  $z$ ,  $z_r$  è l'altezza alla quale la velocità del vento nota  $u_r$  è stata misurata. La rugosità è stata scelta uguale a 0.18 in accordo ad un suolo di campagna e alla scarsa presenza di costruzioni e altri ostacoli.

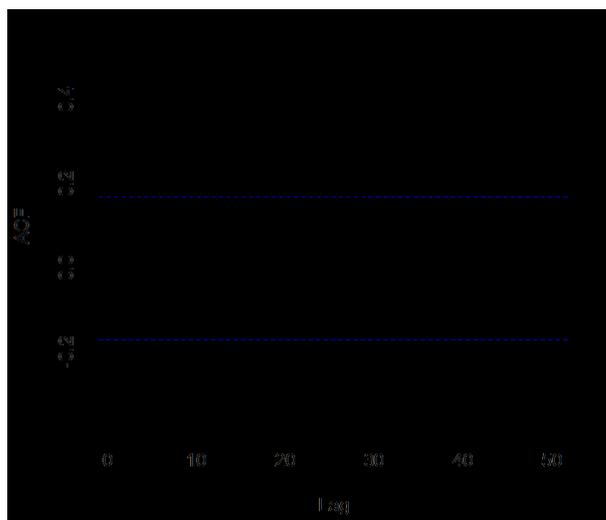
Quando la serie di dati della velocità del vento è stata approntata, è stato scorporato un set di calibrazione costituito da 135 periodi utilizzato poi per la costruzione del modello. Gli ultimi 24 dati disponibili sono stati conservati per essere usati nella successiva fase di validazione del modello: guardando la figura II.9 la linea continua nera rappresenta le misure di calibrazione, mentre la linea rossa tratteggiata è il set di validazione.

Poiché i dati di calibrazione non apparivano normalmente distribuiti è stata effettuata una differenziazione di ordine uno raggiungendo così sia la stazionarietà che una distribuzione normale. Inoltre una eventuale periodicità nei dati è stata indagata diagrammando la funzione di autocorrelazione rispetto al ritardo. In tal modo si è evidenziata una stagionalità giornaliera nei dati differenziati, dato che il ritardo di 24 ore presenta un'elevata autocorrelazione, si guardi la figura II.10.

Per questa particolare serie storica sembra una scelta corretta l'applicazione di un modello ARIMA stagionale con un passo stagionale di 24 ore e una differenziazione dei dati del primo ordine.



**Fig. II.9:** Valori di velocità del vento (medie orarie) nella località di Postiglione durante luglio 2016. Il set di dati è stato diviso in 135 valori di calibrazione (linea nera continua) e in 24 valori di validazione (linea rossa tratteggiata).



**Fig. II.10:** Correlogramma della velocità del vento dopo aver effettuato la differenza del primo ordine. Il valore del coefficiente di autocorrelazione è diagrammato in funzione del ritardo.

Al fine di scegliere la struttura del modello più appropriata è stata prodotta una classificazione delle varie scelte possibili implementando nell'ambiente di lavoro del programma statistico *R* il calcolo dei criteri AIC (Akaike Information Criterion) e BIC (Bayesian Information Criterion). Il risultato è mostrato nella tabella II.7 dove le varie strutture possibili per il modello sono state ordinate secondo il BIC crescente.

**Tab. II.7:** Tavola dei modelli ARIMA testati sulla serie storica della velocità del vento. I modelli sono classificati mediante i valori di BIC e AIC.  $N$  rappresenta il numero di parametri del modello.

Rank	p	d	q	P	D	Q	N	BIC	AIC
1	1	1	0	1	0	1	3	221.99	213.39
2	1	1	1	1	0	0	3	221.99	213.39
3	0	1	0	0	0	2	2	225.46	219.72
4	0	1	2	0	0	0	2	225.46	219.72
5	0	1	0	1	0	2	3	229.23	220.63
6	0	1	2	1	0	0	3	229.23	220.63
7	1	1	0	0	0	2	3	229.23	220.63
8	1	1	2	0	0	0	3	229.23	220.63
9	0	1	1	0	0	2	3	230.32	221.72
10	0	1	2	0	0	1	3	230.32	221.72
11	0	1	1	1	0	2	4	234.13	222.66
12	0	1	2	1	0	1	4	234.13	222.66

Per il fatto che il modello SARIMA(1,1,0)x(1,0,1) minimizza sia AIC che BIC questa struttura sembra ragionevolmente la migliore per descrivere il set di dati osservato. I parametri del modello sono stati stimati nell'ambiente di  $R$  usando il metodo della massimizzazione della verosimiglianza: i risultati sono mostrati nella tabella II.8.

**Tab. II.8:** Valori stimati dei coefficienti e errore standard del modello SARIMA (1,1,0)x(1,0,1)<sub>24</sub>.

Coefficienti	Valore Stimato	Errore Standard
AR1( $\phi$ )	0.4048	0.0822
SAR1( $\Phi$ )	0.9961	0.0358
SMA1( $\Theta$ )	-0.9338	0.2981

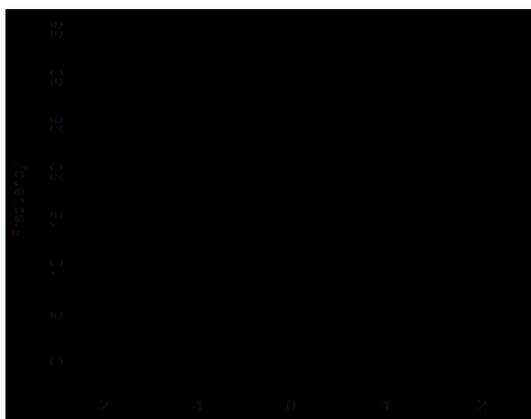
Utilizzando questi coefficienti può essere eseguita la diagnostica del modello sui dati di calibrazione utilizzando la potente tecnica dell'analisi dei residui. Ancora una volta si ricorda che i residui (errori) sono qui definiti secondo la formula I.8.

Le statistiche riassuntive dei residui sono riportate nella tabella II.9 mentre l'istogramma di frequenza è in figura II.11. È evidente che la distribuzione degli errori può essere considerata normale, con media zero e bassa deviazione standard: questo risultato è coerente con l'assunzione teorica del modello. Dopo aver ottenuto una buona calibrazione del modello, lo stesso può essere usato per prevedere la velocità del vento nelle ore successive ai periodi usati per stimare i parametri. Le previsioni ottenute sono state confrontate con i 24 dati reali di validazione e il confronto grafico può essere valutato nella figura II.12. È evidente che la previsione è affetta da uno sfasamento temporale questa è una caratteristica comune per i modelli ARIMA come riportato in [58].

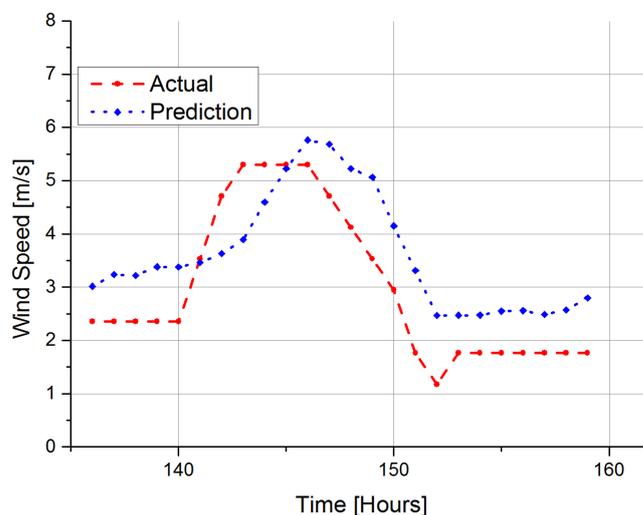
Le statistiche dell'errore in fase di validazione, che possono essere considerate un buon indicatore delle prestazioni previsionali del modello costruito, sono riportate nella tabella II.10. la media dei residui è  $-0.62$  m/s, mostrando un leggera sovrastima delle previsioni. Come era lecito aspettarsi sia la media che la deviazione standard sono aumentate rispetto alla fase di analisi dei residui in calibrazione infatti in quel caso i dati usati per il calcolo degli errori sono gli stessi usati per la stima dei parametri.

**Tab. II.9:** Statistiche riassuntive degli errori valutati sui 135 dati di calibrazione.

Media [m/s]	Dev.Std. [m/s]	Mediana [m/s]	Min [m/s]	Max [m/s]	skew	kurt
0.00	0.48	0.00	-1.44	1.49	0.25	0.47



**Fig. II.11:** Istogramma di frequenza degli errori calcolati sui 135 dati di calibrazione.



**Fig. II.12:** Velocità del vento nei 24 periodi di validazione. La linea rossa mostra i valori reali, la linea blue mostra le previsioni. I dati mostrati sono medie orarie misurate in metri al secondo.

**Tab. II.10:** Statistiche riassuntive degli errori di previsione valutati sui 24 dati di validazione.

<b>Media</b> [m/s]	<b>Dev.Std.</b> [m/s]	<b>Mediana</b> [m/s]	<b>Min</b> [m/s]	<b>Max</b> [m/s]	<b>skew</b>	<b>kurt</b>
-0.62	0.76	-0.8	-1.55	1.41	1.28	0.78

### 2.2.2 Mappa di rumorosità dell'area in presenza del vento previsto

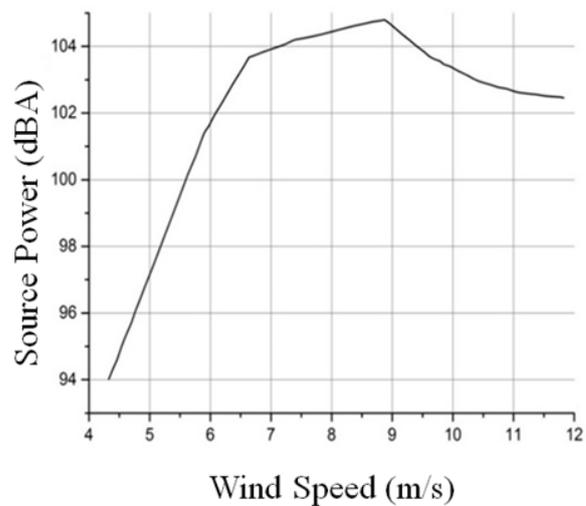
Dopo aver conseguito previsioni affidabili per la velocità del vento in un certo intervallo temporale (nel nostro caso 24 ore), è possibile ottenere una mappatura acustica della zona di interesse. In particolare è stato sfruttato il programma *Cadna-A* impostando la conseguenziale emissione acustica delle turbine eoliche derivata dalla velocità del vento prevista con il modello SARIMA.

Di seguito si è scelto di presentare la mappatura della rumorosità relativa alla velocità media del vento nell'intervallo temporale che va dalle 7:00 alle 19:00 che costituisce l'intervallo "diurno" stabilito dalle direttive europee [81]. Questa velocità media è stata calcolata essere pari a 4.46 m/s: la stessa velocità del vento è funzionalmente legata ad una potenza di emissione acustica dell'aerogeneratore pari a 94.6 dBA, calcolata in accordo alla procedura descritta nell'articolo I (*Integration of ARIMA and Software Models for Wind Speed Forecast and Noise Map Prediction in a Wind Farm*) firmato anche dall'autore di questa tesi. La mappa di rumorosità risultante è mostrata in figura II.14.

Inoltre è stata elaborata la mappa di rumorosità (visibile in figura II.15) relativa alla massima velocità del vento prevista, 5.76 m/s alle 14:00, e legata al massimo valore di emissione acustica per ogni sorgente pari a 100.7 dBA.

Naturalmente in concomitanza con la massima velocità del vento si osservano i valori più alti di rumorosità nella mappatura. L'orografia del terreno influenza la propagazione del campo acustico, e naturalmente anche in questo caso può essere introdotta nel modello la direttività della sorgente per tenere in considerazione anche la direzione del vento.

Una volta che l'area di interesse è stata correttamente modellata nei programmi, la procedura qui presentata può essere sempre applicata per prevedere la velocità del vento e successivamente il campo acustico intorno ai generatori eolici per le successive 24 ore. Queste informazioni possono essere sfruttate per pianificare il tempo di funzionamento delle turbine riducendo l'impatto acustico sugli edifici circostanti. Per la valutazione dell'emissione acustica in funzione della velocità del vento si è fatto riferimento alla curva fornita a corredo dell'aerogeneratore installato, Vestas V52, mostrata in figura II.13 e ampiamente descritta nel manuale del produttore [78].



**Fig. II.13:** Livello di potenza acustica della sorgente in funzione della velocità del vento per una turbina Vestas V52, l'asse della pala è situato ad un'altezza di 65 metri.



**Fig. II.14:** Mappa del rumore relativa alla zona dell'impianto eolico; si è considerata la velocità media del vento prevista con il modello SARIMA. Il livello di potenza della sorgente è 94.6 dBA.



**Fig. II.15:** Mappa della rumorosità relativa alla zona dell'impianto eolico; si è considerata la velocità massima del vento prevista con il modello SARIMA. Il livello di potenza della sorgente è 100.7 dBA.

### 2.2.3 Discussione sui risultati ottenuti

In questa sezione è stato affrontato il problema della previsione della rumorosità prodotta da un parco eolico utilizzando prima una tecnica di analisi delle serie storiche della velocità del vento nella zona di interesse e dopo un programma per la mappatura acustica ambientale. In particolare è stato modellato un parco eolico situato a Postiglione, il software di mappatura ha permesso di eseguire molteplici simulazioni, con diverse velocità del vento e considerandone anche la direzione di provenienza. I risultati hanno mostrato che il funzionamento delle turbine produce una mappa del rumore che è chiaramente influenzata dalla posizione di ciascuna turbina rispetto al pendio della collina. Infatti, anche se la velocità del vento è il parametro più influente nella produzione di rumore, fondamentalmente perché fissa il livello di potenza della sorgente, l'orografia del terreno rappresenta una caratteristica importante nella propagazione del rumore, in quanto influenza la distanza tra le sorgenti e i ricevitori. L'introduzione della direttività della sorgente, correlata alla direzione del vento e, di conseguenza, alla propagazione del campo acustico, ha portato a variazioni significative nella mappatura dei livelli di rumorosità. In particolare, la forma del campo sonoro viene modificata, introducendo, come previsto, uno spostamento dei livelli di rumore nella direzione del vento (si veda I, *Integration of ARIMA and Software Models for Wind Speed Forecast and Noise Map Prediction in a Wind Farm*).

Nella seconda parte della sezione, viene presentato un modello lineare stocastico basato sull'analisi di serie storiche univariate, in particolare qui ci si è soffermati sull'analisi di una sequenza di dati composta dalla velocità media oraria del vento nella regione di interesse. Grazie allo studio del correlogramma dei dati è stato selezionato un modello ARIMA stagionale per la previsione della velocità del vento.

I parametri sono stati valutati su un set di dati di calibrazione di 135 dati di velocità e le previsioni sono state confrontate con 24 dati di validazione. La verifica di affidabilità del modello scelto, svolta con l'analisi dei residui, ha confermato i presupposti teorici (media dell'errore pari a zero e distribuzione normale) nel set di dati di calibrazione e ha mostrato buone prestazioni in termini di statistiche di errore nella fase di validazione. In quest'ultima fase, le previsioni ottenute hanno mostrato una leggera sovrastima e un breve ritardo (tipico dei modelli auto-regressivi) rispetto ai dati reali osservati. Ricordiamo inoltre che l'orizzonte previsionale scelto, in accordo con la marcata periodicità dei dati, è stato scelto pari a 24 ore.

Infine, i valori della velocità del vento previsti sono stati utilizzati come input nel modello software per la mappatura di rumorosità, al fine di produrre mappe dei livelli acustici relative alle condizioni del vento ipotizzate.

La procedura descritta, ossia la fusione della previsione di velocità del vento e la mappatura acustica, è utile per valutare la propagazione del rumore nella zona del parco eolico con qualsiasi condizione di velocità e direzione del vento: fornisce dunque un valido strumento per aiutare sia nella scelta del posizionamento degli aerogeneratori sia nella progettazione complessiva di un parco eolico.

## **Modelli previsionali ibridi**



### 3.1 Un modello ibrido per la previsione di rumorosità acustica basato su metodi di decomposizione deterministici e reti neurali artificiali

La crescita delle aree urbane ha avuto come conseguenza la concentrazione di agenti inquinanti dovuti alle attività dell'uomo [63,82]. I cittadini delle grandi città sono esposti a sostanze gassose tossiche, campi elettromagnetici e ad alti livelli di inquinamento acustico. Una ampia letteratura scientifica documenta gli effetti nocivi dell'esposizione prolungata ad alti livelli di rumore (si veda ad esempio [83-85] e le referenze ivi considerate). Nelle aree urbane una delle sorgenti acustiche più rilevanti è costituita dalle strade percorse dagli autoveicoli, sia leggeri che pesanti e spesso presenti in numero molto elevato anche a ridosso di zone densamente popolate.

Per tali ragioni le amministrazioni pubbliche sono interessate ad un preciso monitoraggio dell'andamento nel tempo dei livelli acustici. Alcuni modelli di previsione di rumore da traffico presenti in letteratura consentono di valutare l'impatto di nuove infrastrutture, ma se usati per la previsione dei livelli acustici attuali necessitano della rilevazione di molti parametri non facilmente e contemporaneamente misurabili, come ad esempio il numero di veicoli che transitano nell'unità di tempo, la velocità di questi, le variabili ambientali come umidità, pressione e temperatura.

Il modello proposto in questa tesi è capace di fornire una previsione del livello acustico solo dall'analisi delle misurazioni di questa grandezza nei periodi precedenti. In particolare per fornire una previsione di lungo periodo viene usata una tecnica di analisi (DD-TSA) della serie storica osservata basata sulla decomposizione del segnale in varie componenti, come ad esempio trend, andamento stagionale e componente casuale: si tratta di un modello simile a quello descritto nel primo capitolo. Le diverse componenti sono poi combinate insieme in un modello misto che moltiplica il trend e i coefficienti stagionali e considera in maniera additiva la componente casuale. Per ottenere una accuratezza previsionale superiore, ma di orizzonte più limitato, si utilizza poi una rete neurale artificiale (ANN) per studiare e prevedere l'andamento della componente casuale che il primo modello DD-TSA non riesce a descrivere in maniera accurata. Infatti la rete neurale è capace di modellare accuratamente anche relazioni di tipo non lineare come quelle che si possono riscontrare tra i valori assunti dalla serie storica in un periodo e quelli osservati in precedenza. La rete neurale è chiamata a prevedere il valore assunto dal termine casuale in un certo periodo  $t$  avendo in ingresso i valori assunti dal termine casuale (quest'ultimo stimato come valore osservato del livello acustico meno il valore previsto dal modello TSA) in un certo numero di periodi precedenti. La previsione totale sarà costituita dalla parte prevista dal modello DD-TSA sommata alla componente casuale prevista dalla rete neurale. La rete neurale utilizzata è del tipo *feed forward backpropagation*; si tratta sostanzialmente di un *multilayer perceptron* molto utilizzato e ben documentato in letteratura [124,125]. La rete è stata sviluppata avvalendosi del *Neural Network Tool* della piattaforma Matlab.

Questo tipo di modello ibrido è particolarmente innovativo per l'uso della combinazione di un modello di decomposizione deterministico insieme ad una rete neurale, infatti in letterature solo modelli stocastici insieme a tecniche ANN sono ben documentati, si veda ad esempio [87] e le referenze in esso contenute.

La costruzione del modello di analisi delle serie storiche DD-TSA è basata sulla rilevazione di una periodicità nei dati e sulla successiva modellazione opportuna dei coefficienti stagionali. E' stato usato il test statistico di Ljung-Box per accertare la presenza di autocorrelazione nei dati, e quindi una periodicità, non trascurabile; successivamente è stato scelto il passo di stagionalità più opportuno mediante la tecnica

della massimizzazione della funzione di autocorrelazione. Questa tecnica ha evidenziato una forte periodicità settimanale nella serie storica studiata.

Per una completa caratterizzazione della serie sono stati implementati test statistici per valutare la linearità e la stazionarietà della stessa.

Il set di dati analizzato è stato ricostruito e completato con una metodologia DD-TSA; metodologia usata molte volte in letteratura [86], con successo, su set di dati analoghi. In particolare i dati realmente misurati sono 1031 mentre quelli ricostruiti sono 169.

Il set di dati studiato è costituito da 1200 dati di livello acustico ponderato con curva A misurati nella città di Messina, in Italia, in prossimità di una trafficata strada non lontano dal porto commerciale. Il passo della serie è giornaliero, ovvero i dati analizzati sono misurazioni fonometriche costituite da livelli continui equivalenti calcolati su sedici ore diurne (ossia il livello equivalente giornaliero prescritto dalla normativa).

Dopo aver costruito il modello DD-TSA questo è stato calibrato sui primi 1100 dati, poi utilizzando gli errori commessi dal modello durante la fase di calibrazione sono state addestrate due reti neurali: la prima, chiamata ANN( $t-1$ ) ha in input gli errori di sette periodi precedenti rispetto a quello che si vuole prevedere; la seconda, chiamata ANN( $t-7$ ) ha in input gli errori di sette periodi a partire da quattordici periodi precedenti rispetto a quello che si vuole prevedere. Quest'ultima rete ha lo scopo di poter estendere la previsione per sette giorni nel futuro sfruttando la forte periodicità settimanale presente nei dati.

Gli ultimi 100 dati disponibili sono stati usati per effettuare un completo test di performance sulle capacità previsionali dei modelli implementati. Si è confrontato l'andamento mediante varie tecniche di analisi dei residui prodotti applicando i modelli ai 100 dati di test. Il *performance test* è stato fatto confrontando il modello DD-TSA usato da solo, il modello DD-TSA con in cascata la rete ANN( $t-1$ ) e infine il modello DD-TSA con in cascata la rete neurale ANN( $t-7$ ).

### 3.1.1 Richiamo al metodo di decomposizione deterministico

Il modello di analisi delle serie storiche usato presuppone che  $A_t$  (dall'inglese *actual value*), il dato osservato al periodo  $t$ , è scomponibile in tre componenti principali: il trend  $T_t$  che moltiplica un coefficiente di stagionalità  $\bar{S}_i$  che rappresenta la seconda componente periodica e poi una componente casuale  $e_t$  aggiunta in maniera additiva che costituisce la parte erratica non prevedibile in maniera deterministica. In generale il modello prevede che il dato reale è dato da una previsione deterministica più una componente casuale:

$$A_t = F_t + e_t . \quad (\text{III.1})$$

Il modello ibrido proposto in questo capitolo prevede che la componente casuale possa essere prevista mediante una rete neurale artificiale che riceve in input osservazioni precedenti della serie storica degli errori generati durante la fase di calibrazione di un modello TSA classico che calcola opportunamente il trend e la stagionalità. Dunque la previsione finale  $F_t$  ottenuta dai due modelli in cascata è data dalla formula seguente:

$$F_t = T_t \bar{S}_i + \hat{e}_t , \quad (\text{III.2})$$

nella quale il modello DD-TSA fornisce la parte deterministica  $T_t \bar{S}_1$  mentre la rete neurale fornisce in output il termine  $\hat{\epsilon}_t$ , ovvero la stima della componente non deterministica.

Una serie storica è un insieme finito cronologicamente ordinato di osservazioni generalmente equidistanti; l'ordine dei dati è la caratteristica peculiare delle serie storiche.

L'analisi delle serie storiche è l'insieme delle procedure che permettono di studiare l'evolversi dei fenomeni al trascorrere del tempo; in particolare una sequenza di dati univariata, mira a descrivere, interpretare, prevedere e controllare una singola serie nella sua dinamica temporale, tentando di spiegare il meccanismo che la genera e di prevederne il comportamento nel suo sviluppo futuro. Dunque la finalità che l'analisi persegue può essere di tipo descrittivo, ossia consistente nel presentare i dati mediante grafici, nel presentarne il contenuto informativo con strumenti statistici e indici sintetici atti a cogliere le caratteristiche della serie storica, fra cui la stazionarietà, la presenza di una tendenza, i segnali di un ciclo, l'esistenza di effetti stagionali, l'identificazione di irregolarità e disomogeneità (dati mancanti o dati abnormi non consistenti con gli altri e dovuti ad annate sfavorevoli, calamità naturali, scioperi, guerre, effetti di calendario, errori di rilevazione), nonché a individuare punti di discontinuità (cioè improvvisi cambiamenti di livello, che spesso rivelano modificazioni determinatesi nella struttura interna dei dati anche per effetto di interventi di politica economica o sociale). Analisi di tipo esplicativo hanno come obiettivo la ricerca del meccanismo che può aver dato origine all'andamento nel tempo dell'insieme delle osservazioni - espresso da un modello matematico ipotetico, capace di riprodurre i dati che compongono la serie storica come realizzazione del processo generatore.

L'analisi delle serie storiche ha spesso finalità previsionale, volte a stimare l'andamento nel tempo del segnale studiato a breve, medio o lungo termine. Le previsioni vengono generalmente elaborate assumendo che i fattori che hanno manifestato rilevanza nell'evoluzione temporale passata agiscano e interagiscano anche per il futuro con le stesse modalità. Previsioni accurate richiedono analisi approfondite per rilevare tempestivamente possibili cambiamenti strutturali nell'andamento della serie.

Lo studio e la modellazione delle serie storiche viene svolta seguendo due principali approcci, concepiti rispettivamente nel dominio frequenziale e nel dominio temporale. Nel dominio frequenziale l'obiettivo è la scomposizione spettrale della serie storica nelle sue componenti periodiche fondamentali, ciascuna caratterizzata da un differente ammontare di varianza; in quello temporale i modelli vengono formulati in termini di tempo, di rapporti passato-presente, di memoria della serie, di autocovarianza e autocorrelazione tra i dati. I due approcci sono matematicamente equivalenti, come dimostrato da Wiener e Khintchine (v. Gottman, 1981, cap. 16), essendo metodiche diverse ma complementari per descrivere e modellare i dati; la costruzione di un modello del processo generatore della serie osservata può essere realizzata usando modelli frequenziali, modelli temporali e modelli integrati, e la più opportuna modellazione può ottenersi impiegando come strumenti di base la funzione di densità spettrale e la funzione di autocorrelazione; per una trattazione esaustiva sull'argomento si rimanda alla seguente letteratura selezionata in lingua italiana: 1) Di Fonzo Tommaso, Lisi Francesco, "Serie storiche economiche", Carocci editore, 2006) e a 2) Giusti Franco, Vitali Ornello, "Statistica Economica", Cacucci editore, 1993.

In questo capitolo, come anche nel primo, è stato implementato un modello di analisi delle serie storiche di decomposizione deterministico, per componenti, che si basa sull'assunzione che il trend possa essere semplicemente descritto da una regressione lineare caratterizzata dai coefficienti  $b_0$  e  $b_1$  calcolati sui dati osservati, mentre i coefficienti di stagionalità esprimono il carattere periodico e ricorsivo della serie

osservata e sono calcolati in accordo con le formule presentate nel primo capitolo. Dunque per questo modello, denominato DD-TSA, la previsione del livello acustico nel sito di riferimento  $\hat{F}_t$  è calcolata mediante la formula:

$$\hat{F}_t = (b_0 + b_1 t) \bar{S}_i . \quad (\text{III.3})$$

Il primo errore di previsione stimato  $e_t^*$ , considerando il modello DD-TSA, può essere definito come:

$$e_t^* = A_t - \hat{F}_t . \quad (\text{III.4})$$

Dunque in generale vale che il valore reale della serie, non prevedibile perfettamente a causa delle fluttuazioni casuali, può essere valutato, ad ogni periodo  $t$ , in accordo con la formula III.2, e  $\Delta_t$ , che è errore totale di previsione del modello ibrido proposto, può essere definito come:

$$\Delta_t = A_t - (\hat{F}_t + \hat{e}_t) \quad (\text{III.5})$$

### 3.1.2 Reti neurali artificiali

Una rete neurale artificiale è sostanzialmente costituita dall'unione di funzioni matematiche molto semplici che agiscono in una struttura massicciamente parallela capace di apprendere simulando il comportamento del cervello umano. Le funzioni che concorrono al lavoro della rete vengono dette neuroni artificiali perché sono state disegnate sul modello di funzionamento di questa struttura biologica presente nel cervello. Il neurone artificiale è apparentemente semplice se considerato singolarmente ma capace di formidabili prestazioni quando agisce in concomitanza con altre funzioni analoghe presenti in una rete neuronale opportunamente realizzata. Il neurone artificiale, tipicamente, ha molti ingressi ai quali è associato un peso e una sola uscita. L'attivazione del singolo neurone è funzione della somma pesata degli ingressi. Questa struttura matematica al pari di un cervello biologico ha attitudine non solo ad apprendere ma anche a generalizzare, ovvero di produrre uscite corrette in presenza di ingressi mai incontrati nella fase di addestramento.

Il metodo più usato per addestrare una rete neurale consiste nel presentare in input una serie di esempi (*training set*). La risposta della rete per ogni esempio viene confrontata con la risposta desiderata, si valuta la differenza tra le due (errore)  $e$ , in base a tale differenza, si aggiustano i pesi. Questo processo viene ripetuto sul *training set* finché le uscite della rete producono un errore al di sotto della soglia stabilita. È importante notare che in questo processo di apprendimento non sarà stata effettuata alcuna ipotesi sulle relazioni esistenti tra i dati di input e l'uscita: sarà la rete a riconoscere una eventuale relazione informativa che consentirà di prevedere il comportamento della variabile dipendente (uscita) per mutate condizioni delle variabili indipendenti (ingressi). Questo aspetto, unito alle capacità della rete di descrivere relazioni matematiche fortemente non lineari, ha decretato il successo di questa tecnica in molte applicazioni ingegneristiche. Tuttavia è sempre preferibile indagare le relazioni tra le variabili di interesse mediante

metodi classici, come ad esempio regressioni lineari, finché è possibile poiché queste tecniche consentono di controllare quali sono le rispettive influenze delle variabili in ingresso sulle variabili dipendenti. La rete neurale non fornisce nessuna informazione, né di tipo qualitativo né di tipo quantitativo, sugli effetti che le singole variabili in ingresso hanno su quelle in uscita. Per una trattazione generale delle reti neurali applicate a problemi ingegneristici si può fare riferimento a Beatrice Lazzerini, “Introduzione alle Reti Neurali” [126].

Le reti neurali artificiali (ANN) sono state applicate con successo ad un’ampia tipologia di problemi ingegneristici. Uno dei vantaggi di questa modellazione consiste nel fatto che non è necessario conoscere nessun tipo di relazione specifica che esiste tra i dati analizzati, i relativi modelli funzionali, il tipo di distribuzioni e altre informazioni non sempre note. Le ANN forniscono una ricca, potente e robusta modellazione non parametrica con provata efficacia e potenziale per applicazioni in molti campi delle scienze. I vantaggi non indifferenti delle ANN hanno incoraggiato i ricercatori ad usare questa tecnica in un ampio spettro di applicazioni relative al mondo reale. In alcuni casi tale modellazione è un’alternativa migliore, sostitutiva o complementare, a schemi computazionali più tradizionali per risolvere problemi ingegneristici. In diverse applicazioni scientifiche ed ingegneristiche sistemi che hanno una struttura complessa sconosciuta presentano segnali misurabili in ingresso e in uscita. Una ANN, in concomitanza con un appropriato algoritmo di apprendimento, può essere efficacemente utilizzata per apprendere relazioni complesse e non lineari esistenti tra vettori di ingressi e uscite.

Ci sono alcune fondamentali ragioni per tentare la modellazione di un fenomeno fisico osservato mediante una rete neurale artificiale, possiamo elencarne le principali:

- Le ANN hanno la non banale capacità di modellare relazioni tra ingressi e uscite fortemente non lineari.
- La rete neurale apprende le caratteristiche principali del fenomeno attraverso un processo iterativo di addestramento. Essa può automaticamente aggiornare la propria conoscenza acquisita in tempo reale continuando ad operare. Queste proprietà di apprendimento automatico rendono le ANN sistemi fondamentalmente auto-adattativi.
- Le ANN possono essere un previsore molto affidabile: le tecniche previsionali che le utilizzano sono strumenti appropriati per stimare l’andamento di un fenomeno attraverso la conoscenza del suo comportamento nel passato. Grazie a questo strumento è possibile definire la relazione (lineare o non lineare) che sussiste tra un elevato numero di variabili anche senza la loro approfondita conoscenza.

Dunque, se sono disponibili lunghe serie storiche con dati di interesse, una rete neurale appropriatamente addestrata con questi dati, regolando i pesi delle connessioni neurali, sarà in grado di prevedere una variabile di interesse con un piccolo errore quando verrà applicata a nuovi dati con caratteristiche similari rispetto a quelli usati per l’addestramento.

### *3.1.3 Analisi preliminare del set di dati di calibrazione*

Il set di dati utilizzato per la fase di calibrazione è costituito da misurazioni fonometriche misurate nella città di Messina, in località Viale Bocchetta; la serie storica originaria è la stessa dalla quale sono stati estratti i dati dell’analisi proposta nel primo

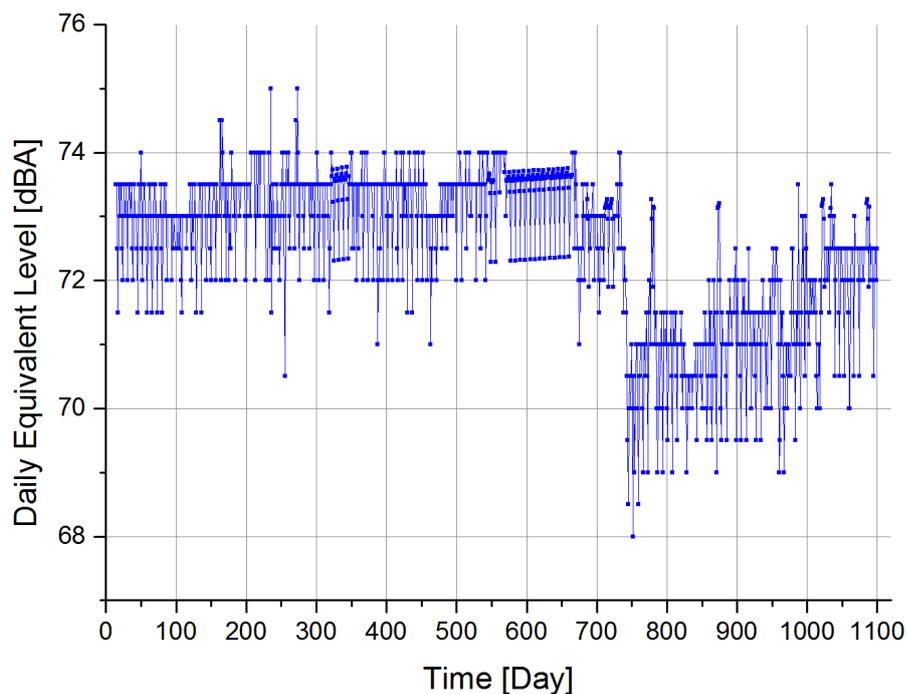
capitolo. Dunque sono stati utilizzati livelli acustici equivalenti calcolati giornalmente in un intervallo di 16 ore, dalle 6:00 alle 22:00; le misure vanno dal periodo (giorno) denominato 1 al periodo (giorno) 1100, ossia dall'11 maggio 2007 al 14 maggio 2010.

Si è deciso di fornire in questa sezione alcune analisi preliminari svolte su 1087 dati, ottenuti non utilizzando i primi 13 valori disponibili: infatti non si è potuto effettuare un confronto previsionale sui primi tredici dati né sulla fase di calibrazione né in quella successiva di performance test dato che per uno dei tre modelli proposti (DD+ANN(t-7)) sono necessari almeno 13 dati in input di periodi precedenti rispetto a quello per il quale si vuole ottenere una previsione. In figura III.1 è mostrata la serie storica utilizzata: il dataset è molto interessante per la brusca variazione di trend che si registra tra il periodo 700 e 800. Nella Tabella III.1 sono mostrate delle statistiche riassuntive calcolate sui 1087 dati del periodo di calibrazione: la media misurata di oltre 72 dBA ci consente di capire che ci si trova in una zona urbana ad alto inquinamento acustico. Nei 1087 giorni non si è mai registrato un livello di rumore inferiore ai 68 dBA. Gli indici di asimmetria e curtosi indicano che la distribuzione delle misure può considerarsi normale. In generale infatti la asimmetria sarà positiva con coda a destra, negativa con coda a sinistra: se tale indicatore è pari a zero la distribuzione è simmetrica. L'indice di curtosi calcolato mediante la piattaforma per elaborazioni statistiche "R" vale zero per una distribuzione normale. Il plot in figura III.2 mostra che in più del 90 % dei giorni considerati il livello acustico misurato è stato superiore ai 70 dBA. Il correlogramma di figura III.3, dove è mostrata la funzione di autocorrelazione data dalla formula I.21 calcolata al variare del *lag* (ritardo), conferma che i valori della serie studiata sono fortemente autocorrelati. Il valore massimo della funzione di autocorrelazione è dato per un lag pari a 7: infatti il rumore prodotto dal traffico veicolare è fortemente influenzato dal numero di veicoli in transito, numero che varia a seconda del giorno della settimana considerato.

Al fine di valutare la presenza di autocorrelazione nella serie studiata, è stato eseguito il test statistico di Ljung-Box (LB). I risultati sono stati riportati nella tabella III.2: il basso valore del *p*-value, ossia la piccolissima probabilità di osservare il campione se l'ipotesi nulla fosse vera, indica che l'ipotesi di assenza di autocorrelazione nei dati può essere rifiutata.

Sono stati inoltre effettuati i test di linearità Lee-White-Granger (LWG) e Terasvirta-Lin-Granger (TLG) nell'ambiente software di "R". I risultati livelli di probabilità molto bassi, riportati nella tabella III.3, suggeriscono il rifiuto dell'ipotesi nulla, ossia la linearità della serie storica. Il risultato dei test e le buone prestazioni dei modelli qui presentati evidenziano la capacità di questi di riprodurre l'andamento non lineare della serie.

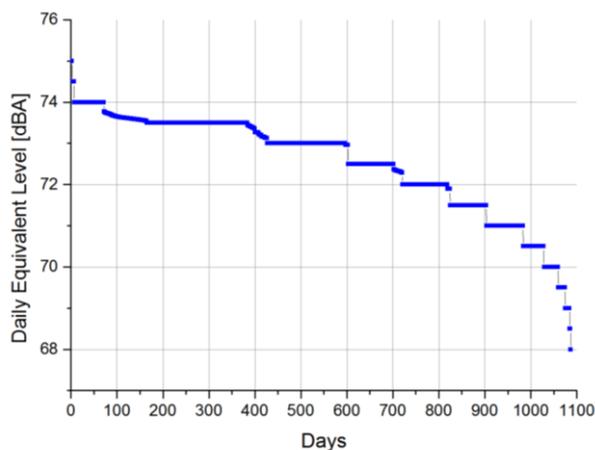
Infine il valore del *p*-value ottenuto dai test di Dickey-Fuller e Phillips-Perron applicati ai dati, valori mostrati in tabella III.4, non consentono di rifiutare l'ipotesi nulla della presenza di radici unitarie nel processo analizzato: è dunque verosimile che la serie storica sia non-stazionaria. Nel prosieguo della trattazione mostreremo che nonostante l'assenza di stazionarietà dovuta alla brusca variazione di media nel periodo di tempo considerato, i modelli proposti sono nel complesso in grado di fornire buoni risultati in termini di previsione.



**Fig. III.1:** Serie storica dei 1100 dati reali usati nella fase di calibrazione; il periodo temporale mostrato va dall'11 maggio 2007 al 14 maggio 2010.

**Tab. III.4:** Statistiche riassuntive del livello equivalente misurato durante 1087 giorni del set di dati di calibrazione.

Media [dBA]	Dev. Std. [dBA]	Mediana [dBA]	Min [dBA]	Max [dBA]	Skew.	Kurt.
72.54	1.20	73.0	68.0	75.0	0.24	0.04



**Fig. III.2:** Livello acustico equivalente giornaliero misurato nella serie di calibrazione diagrammato in ordine decrescente di magnitudo. L'asse  $x$  riporta il numero di giorni nei quali il corrispondente livello di rumorosità è superato.

**Tab. III.2:** Test di Ljung-Box applicato a 1087 misure del set di dati di calibrazione.

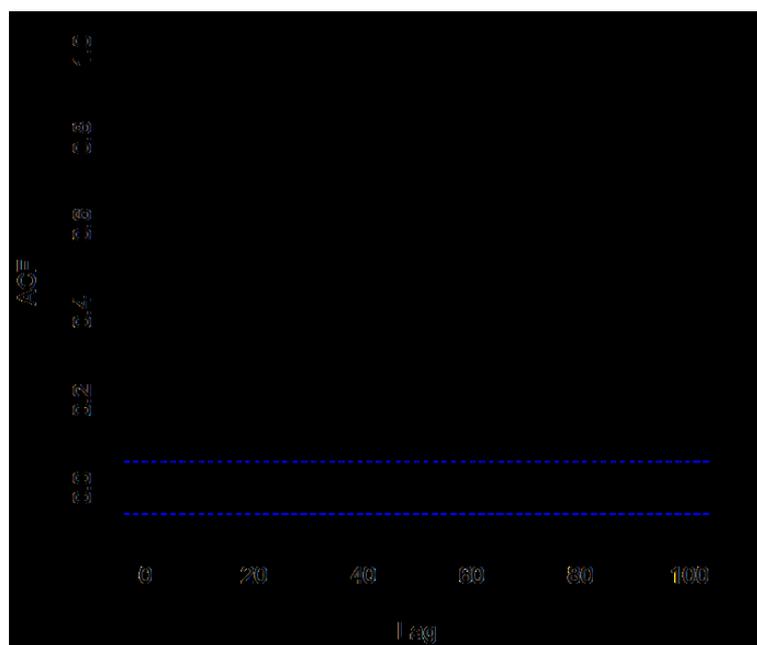
Test	$\chi^2$	$d$	$p$ -value
Ljung-Box	8912.113	20	$< 2.2 \times 10^{-16}$

**Tab. III.3:** Test di linearità di Lee-White-Granger (LWG) e Terasvirta-Lin-Granger (TLG) applicati a 1087 dati di calibrazione.

Test	Statistica del test	$df$	$p$ -value
LWG	46.098	2	$9.77 \times 10^{-11}$
TLG	47.024	2	$6.15 \times 10^{-11}$

**Tab. III.4:** Test di stazionarietà di Dickey-Fuller e Phillips-Perron applicati a 1087 dati di calibrazione.

Test	Statistica del test	Lag	$p$ -value
Augmented Dickey-Fuller	-3.779	10	0.020
Phillips-Perron	-15.850	7	0.01

**Fig. III.3:** Correlogramma del set di dati di calibrazione.

### 3.1.4 Dettagli del modello DD-TSA

In questo paragrafo viene descritta l'applicazione del modello DD-TSA ai 1100 dati di calibrazione descritti e analizzati nella sezione precedente. Per costruire un modello di decomposizione deterministico (si veda a tal proposito anche l'estesa trattazione nel primo capitolo) è necessario stimare i parametri per il calcolo del trend e calcolare opportunamente i coefficienti di stagionalità utilizzando per tale fine i dati disponibili in quello che viene detto dataset di calibrazione del modello. Per preservare la capacità del modello DD-TSA di effettuare previsioni in un intervallo temporale molto lontano rispetto ai dati conosciuti si è deciso di considerare un trend dato da una semplice regressione lineare a due parametri (linea retta). Infatti anche se questo tipo di trend perde alcuni dettagli della serie su orizzonti di previsione brevi, è quello che in media sbaglia meno quando si vuole estendere di molto la previsione. A tale scopo si è deciso di utilizzare per la calibrazione tutti e 1100 dati disponibili anche se sarebbe stato possibile considerare i dati per calibrare il trend solo a partire dal periodo 750, ovvero dopo che si è verificata la brusca variazione di trend osservabile in figura III.1 tra il periodo 700 e 800. In definitiva si è deciso di adottare un modello DD-TSA in accordo con il tipo mostrato nella formula III.3. Il calcolo della funzione di autocorrelazione ha mostrato che il suo valore massimo si ha per un valore del lag (ritardo) pari a 7. Questo dato ci guida a scegliere un modello di analisi delle serie storiche che prevede la presenza di sette diversi coefficienti di stagionalità: uno per ogni giorno della settimana. Nella tabella III.5 possiamo vedere i valori ottenuti per i parametri del trend: nei 1100 giorni del periodo di calibrazione la pendenza della retta di trend,  $-0.001997$  dBA/day, mostra una lieve riduzione del livello di rumore con il trascorrere del tempo; inoltre l'intercetta della retta di trend al periodo zero mostra un valore di livello acustico molto elevato: ben 73.6 dBA. I sette coefficienti di stagionalità calcolati mostrano che i livelli acustici più bassi sono stati osservati nei giorni di sabato e domenica: giorni festivi nei quali la densità del traffico veicolare è minore e dunque sono necessari coefficienti minori di uno per ottenere una correzione in diminuzione della previsione data dal trend.

**Tab. III.5:** Parametri e coefficienti del modello DD-TSA stimati sui dati di calibrazione.

$b_0$	73.63809
$b_1$	0.001997
$\bar{S}_1$ lunedì	1.00143
$\bar{S}_2$ martedì	1.00287
$\bar{S}_3$ mercoledì	1.00323
$\bar{S}_4$ giovedì	1.00371
$\bar{S}_5$ venerdì	1.00414
$\bar{S}_6$ sabato	0.99805
$\bar{S}_7$ domenica	0.98650

### 3.1.5 Dettagli del primo modello di rete neurale ANN( $t-1$ )

In questo paragrafo vengono descritte la costruzione e l'implementazione delle due reti neurali che hanno lo scopo di migliorare la previsione grazie alla stima della componente casuale ottenuta utilizzando in input sette diversi errori di previsione del modello DD-TSA in periodi precedenti.

Dopo aver effettuato la previsione del livello di rumore acustico mediante il modello DD-TSA, usiamo l'errore ( $e_t^*$  calcolato in accordo alla formula III.4) registrato in ogni periodo dell'intervallo di calibrazione, dato dal valore di emissione reale meno quello previsto, come segnale in ingresso ad una rete neurale del tipo feedforward. La notazione  $e_t^*$  è usata per indicare l'errore generato durante l'applicazione dal modello DD-TSA, la notazione  $\hat{e}_t$  è usata per indicare l'errore previsto dalla rete neurale, entrambi gli errori nel periodo  $t$ . I neuroni di input sono 7:

**Tab. III.6:** Struttura topologica della prima rete neurale ANN( $t-1$ ).

Ingressi	Singolo strato nascosto	Uscita
$e_{t-1}^*$	140 Neuroni	$\hat{e}_t$
$e_{t-2}^*$		
$e_{t-3}^*$		
$e_{t-4}^*$		
$e_{t-5}^*$		
$e_{t-6}^*$		
$e_{t-7}^*$		

Il vettore di output desiderato è costituito dagli errori  $\hat{e}_t$ .

Come set di dati di calibrazione usiamo gli errori generati durante le previsioni dal periodo 1 al periodo 1100 (11 maggio 2007 al 14 maggio 2010).

Usiamo un solo strato nascosto con numero di neuroni pari a venti volte gli ingressi (140 neuroni) e naturalmente un solo neurone d'uscita.

Dividiamo questo set di dati usando la funzione *dividerand* del Neural Network Tool di Matlab: il *training set* vero e proprio è pari al 60% dei 1100 dati, il set per la *cross-validation* e quello per il "test" sono pari rispettivamente al 20% dei dati.

La funzione di trasferimento per i neuroni dello strato nascosto è del tipo *tansig* (sigmoide), quella dei neuroni di uscita è *purelin* (lineare). La funzione obiettivo da minimizzare è il *mse* (*mean squared normalized error performance function*) e si è impostato l'arresto dell'algoritmo di apprendimento al raggiungimento del valore 0.01.

La funzione di apprendimento usata è *learngdm* (*gradient descent with momentum weight and bias learning function*).

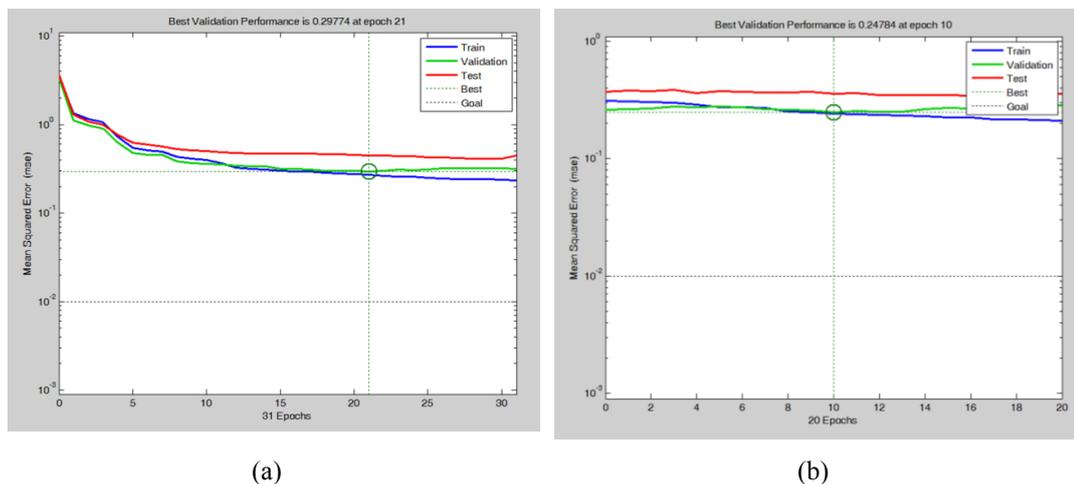
L'algoritmo di addestramento scelto è *trainscg* (*scaled conjugate gradient backpropagation*). Per una trattazione dettagliata di questo algoritmo di apprendimento si veda: Moller, Neural Networks, Vol. 6, 1993, pp. 525 to 533.

La *cross-validation* è una strategia volta ad aumentare le capacità di generalizzazione della rete e a ridurre i rischi dell'*overfitting*. Il massimo numero impostato di peggioramenti accettati nella fase di validazione prima dell'arresto dell'algoritmo è 10.

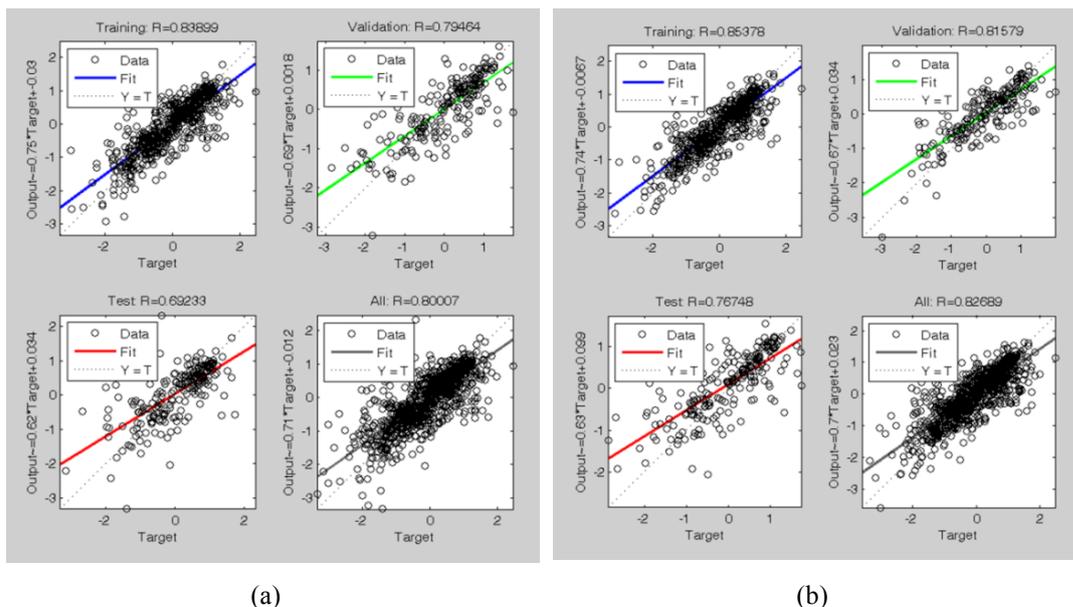
Infatti gli errori di previsioni sul set di dati di validazione normalmente decrescono dopo la fase iniziale dell'addestramento, così come avviene per gli errori sui dati di *training*. Tuttavia quando la rete si sta adattando eccessivamente ai dati di addestramento, gli errori sui dati di validazione cominciano a crescere. Quando questo errore sulla validazione cresce continuamente per un numero di volte specificato (nel nostro caso 10 volte) l'addestramento si conclude e la rete si regola con i pesi e le soglie relative all'ultima iterazione prima della crescita dell'errore sulla validazione.

Nel caso specifico sono stati eseguiti due cicli di calibrazione al fine di ottenere la più elevata minimizzazione della funzione obiettivo. I risultati sono mostrati nella figura III.4: il valore più basso raggiunto per la funzione obiettivo sui dati di validazione è stato di 0.30 per la prima calibrazione e 0.25 per la seconda; questi risultati sono stati raggiunti dopo 21 epoche per il primo ciclo e dopo altre 10 epoche del secondo ciclo.

In figura III.5 sono riportate le rette di regressione, con le relative funzioni, ottenute confrontando i dati obiettivo (gli errori del DD-TSA) con quelli previsti dalla rete durante l'addestramento: il coefficiente di correlazione, ottenuto considerando l'intero set di 1100 dati di calibrazione, è stato di 0.80 alla fine del primo ciclo e di 0.82 alla fine del secondo ciclo. La rete adottata nelle seguenti applicazioni previsionali è quella con i pesi calcolati alla fine del secondo ciclo di addestramento.



**Fig. III.4:** Minimizzazione dell'errore raggiunta durante il processo di addestramento della rete ANN( $t-1$ ): (a) prima calibrazione, l'errore quadratico medio (MSE) raggiunto dopo 21 epoche è 0.30; (b) seconda calibrazione, dopo altre 10 epoche l'MSE raggiunto è 0.25.



**Fig. III.5:** Linee di regressione dopo il processo di addestramento della rete ANN( $t-1$ ): la linea blu è relativa al 60% della serie di errori usata per il training; la linea verde è relativa al 20% dei dati usati per la validazione incrociata e la linea rossa è relativa al 20% dei dati usati per il test. Con la linea nera si confrontano il 100% dei dati osservati con quelli previsti dopo aver assegnato i pesi. Le figure sono relative alla: (a) prima calibrazione; (b) seconda calibrazione.

### 3.1.6 Dettagli del secondo modello di rete neurale ANN( $t-7$ )

Le caratteristiche della rete neurale usata sono identiche rispetto al modello ANN( $t-1$ ), tuttavia si è scelto di spostare indietro di una settimana il vettore di input per ottenere l'estensione della previsione nei sette giorni successivi.

Ad esempio ipotizzando di trovarsi oggi al periodo  $t-1$  (Lunedì) e dunque conoscendo l'errore commesso oggi, è possibile estendere la previsione al periodo  $t+6$  (Lunedì della prossima settimana) avendo in input al modello gli errori dal periodo  $t-7$  ad oggi. Lo spostamento temporale del vettore di input alla rete con il relativo proiettarsi nel futuro della previsione è mostrato in figura III.6.

**Tab. III.7:** Struttura topologica della seconda rete neurale ANN( $t-7$ ).

Ingressi	Singolo strato nascosto	Uscita
$e_{t-7}^*$	140 Neuroni	$\hat{e}_t$
$e_{t-8}^*$		
$e_{t-9}^*$		
$e_{t-10}^*$		
$e_{t-11}^*$		
$e_{t-12}^*$		
$e_{t-13}^*$		

Dunque per avere in output dalla rete la previsione dell'errore al periodo  $t$ , in input sono necessari i sette ingressi mostrati nella tabella III.7.

Wednesday	Thursday	Friday	Saturday	Sunday	Monday	Tuesday	Wednesday	Thursday	Friday	Saturday	Sunday	Monday	Tuesday	Wednesday	Thursday	Friday	Saturday	Sunday	Monday
t-13	t-12	t-11	t-10	t-9	t-8	t-7	t-6	t-5	t-4	t-3	t-2	t-1	t	t+1	t+2	t+3	t+4	t+5	t+6
Wednesday	Thursday	Friday	Saturday	Sunday	Monday	Tuesday	Wednesday	Thursday	Friday	Saturday	Sunday	Monday	Tuesday	Wednesday	Thursday	Friday	Saturday	Sunday	Monday
t-13	t-12	t-11	t-10	t-9	t-8	t-7	t-6	t-5	t-4	t-3	t-2	t-1	t	t+1	t+2	t+3	t+4	t+5	t+6
Wednesday	Thursday	Friday	Saturday	Sunday	Monday	Tuesday	Wednesday	Thursday	Friday	Saturday	Sunday	Monday	Tuesday	Wednesday	Thursday	Friday	Saturday	Sunday	Monday
t-13	t-12	t-11	t-10	t-9	t-8	t-7	t-6	t-5	t-4	t-3	t-2	t-1	t	t+1	t+2	t+3	t+4	t+5	t+6
Wednesday	Thursday	Friday	Saturday	Sunday	Monday	Tuesday	Wednesday	Thursday	Friday	Saturday	Sunday	Monday	Tuesday	Wednesday	Thursday	Friday	Saturday	Sunday	Monday
t-13	t-12	t-11	t-10	t-9	t-8	t-7	t-6	t-5	t-4	t-3	t-2	t-1	t	t+1	t+2	t+3	t+4	t+5	t+6
Wednesday	Thursday	Friday	Saturday	Sunday	Monday	Tuesday	Wednesday	Thursday	Friday	Saturday	Sunday	Monday	Tuesday	Wednesday	Thursday	Friday	Saturday	Sunday	Monday
t-13	t-12	t-11	t-10	t-9	t-8	t-7	t-6	t-5	t-4	t-3	t-2	t-1	t	t+1	t+2	t+3	t+4	t+5	t+6
Wednesday	Thursday	Friday	Saturday	Sunday	Monday	Tuesday	Wednesday	Thursday	Friday	Saturday	Sunday	Monday	Tuesday	Wednesday	Thursday	Friday	Saturday	Sunday	Monday
t-13	t-12	t-11	t-10	t-9	t-8	t-7	t-6	t-5	t-4	t-3	t-2	t-1	t	t+1	t+2	t+3	t+4	t+5	t+6
Wednesday	Thursday	Friday	Saturday	Sunday	Monday	Tuesday	Wednesday	Thursday	Friday	Saturday	Sunday	Monday	Tuesday	Wednesday	Thursday	Friday	Saturday	Sunday	Monday
t-13	t-12	t-11	t-10	t-9	t-8	t-7	t-6	t-5	t-4	t-3	t-2	t-1	t	t+1	t+2	t+3	t+4	t+5	t+6

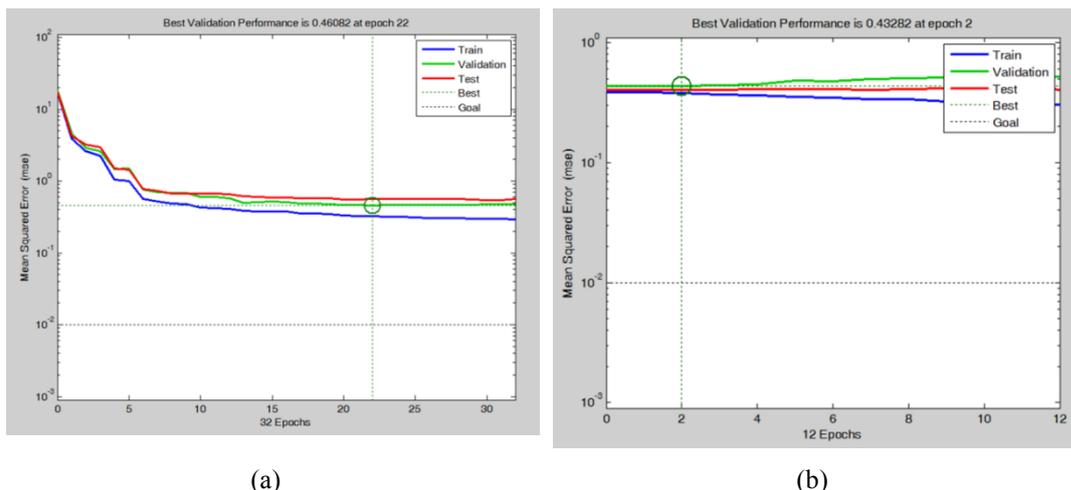
**Fig. III.6:** Il grafico mostra l'avanzamento temporale del vettore degli ingressi costituito dagli errori nei differenti periodi. In giallo ci sono i giorni nei quali la previsione è calcolata; in arancio sono mostrati i periodi necessari come ingressi alla rete; in verde è presentata l'uscita del sistema, ossia il periodo previsto dal modello.

A causa della periodicità settimanale del set di dati, ottiene buoni risultati previsionali anche la rete neurale che ha come vettori di input gli errori commessi in una settimana precedente rispetto a quella considerata. Con questo modello è possibile stimare l'errore commesso dal modello DD-TSA in sette periodi successivi rispetto a quello nel quale ci si trova.

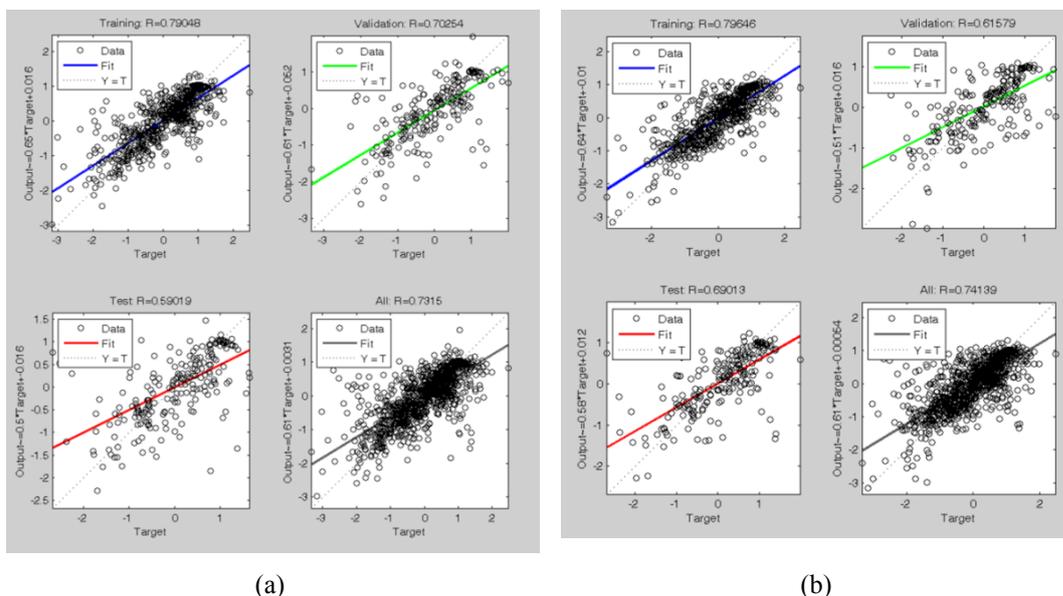
Anche in questo caso sono stati eseguiti due cicli di calibrazione al fine di ottenere la minimizzazione della funzione obiettivo. I risultati sono mostrati nella figura III.7: il valore più basso raggiunto per la funzione obiettivo sui dati di validazione è stato di 0.46 per la prima calibrazione e 0.43 per la seconda; questi risultati sono stati raggiunti dopo 22 epoche per il primo ciclo e dopo altre 2 epoche del secondo ciclo.

In figura III.8 sono riportate le rette di regressione, con le relative funzioni, ottenute confrontando i dati obiettivo con quelli previsti dalla rete durante l'addestramento.

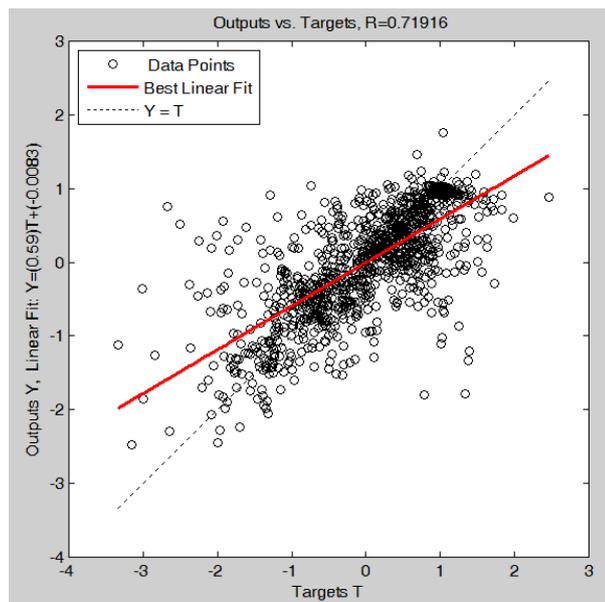
La rete è stata in seguito utilizzata ai fini previsionali con i pesi calcolati durante il secondo ciclo di calibrazione. In figura III.9 sono mostrati i risultati previsionali della rete così addestrata applicata al set di 1100 dati usati in fase di calibrazione: in questo caso le ottime prestazioni previsionali sono confermate da un coefficiente di correlazione pari a 0.72.



**Fig. III.7:** Minimizzazione dell'errore raggiunta durante il processo di addestramento della seconda rete ANN( $t-7$ ): (a) prima calibrazione, l'errore quadratico medio (MSE) raggiunto dopo 22 epoche è 0.46; (b) seconda calibrazione, dopo altre 2 epoche l'MSE raggiunto è 0.43.



**Fig. III.8:** Linee di regressione dopo il processo di addestramento della seconda rete ANN( $t-7$ ): la linea blu è la regressione lineare sul 60% della serie di errori usata per l'addestramento; la linea verde è relativa al 20% dei dati usati per la validazione incrociata e la linea rossa è relativa al 20% dei dati usati per il test. L'ultimo diagramma con linea nera è relativo alla retta approssimante la serie di calibrazione dopo aver calcolato i pesi della rete. Le figure sono relative alla: (a) prima calibrazione; (b) seconda calibrazione.



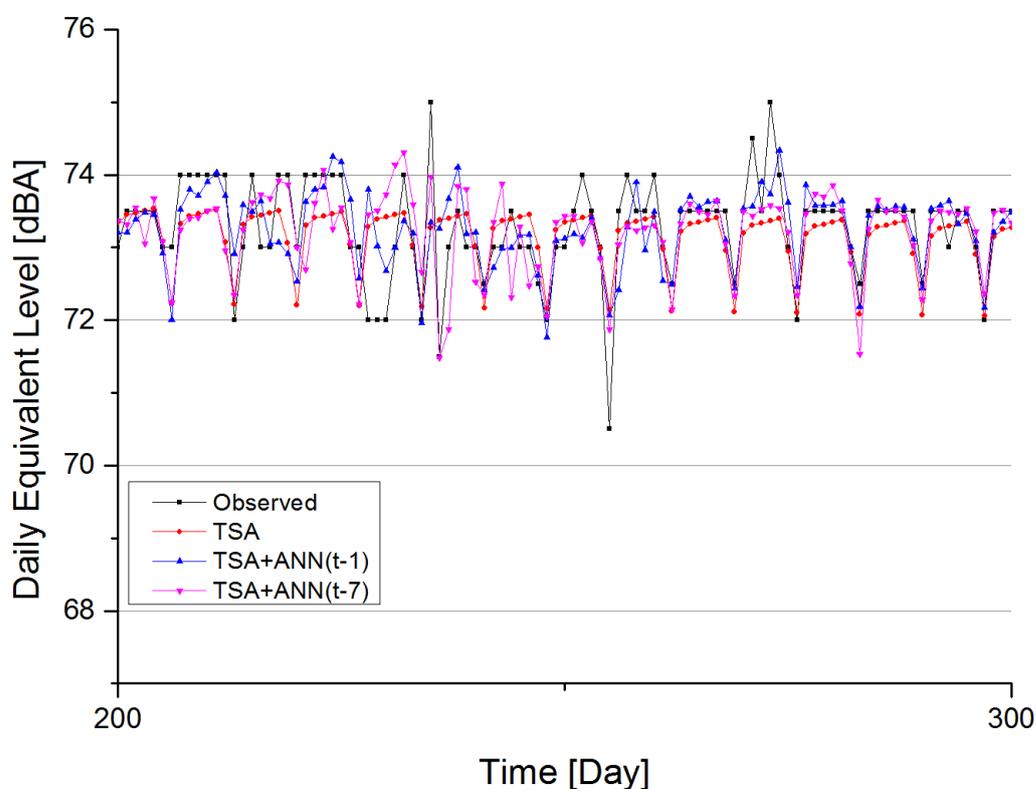
**Fig. III.9:** Retta di regressione per le uscite della rete ANN( $t-7$ ) dopo aver calcolato i pesi e rimostrato alla rete il set di ingressi di calibrazione. Il grafico è relativo alla rete addestrata dopo la seconda calibrazione.

### 3.1.7 Confronto dei modelli tramite grafici della serie storica

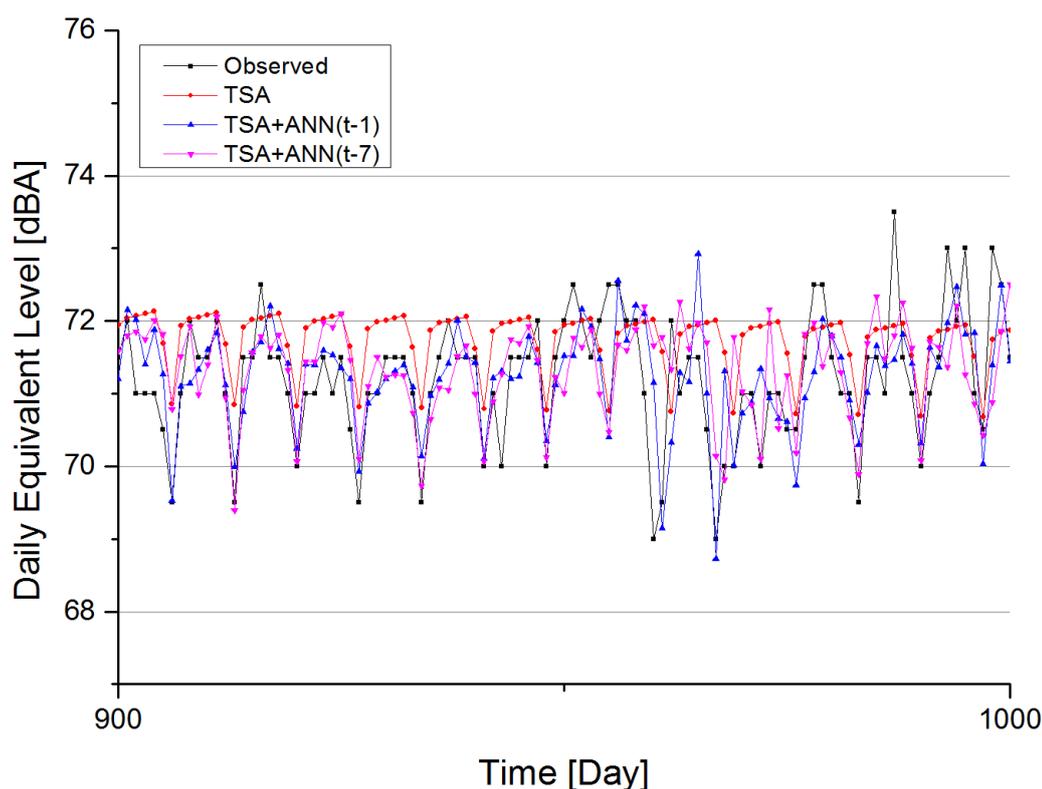
Dopo aver stimato i parametri e i coefficienti dei tre modelli utilizzando i 1100 dati di calibrazione, è possibile effettuare un primo confronto tra le performance previsionali. In questa sezione verrà effettuato prima un confronto qualitativo analizzando, mediante grafici, i dati effettivamente misurati e quelli previsti dai tre modelli dopo essere stati opportunamente calibrati. Nella parte finale della sezione verranno effettuati dei confronti quantitativi basati sugli errori di previsione finali commessi dai tre modelli. Il confronto verrà effettuato sugli stessi dati del dataset di calibrazione, ovvero i 1087 periodi dal 24 Maggio 2007 al 14 Maggio 2010. Si ricorda che i primi 13 giorni del dataset non sono utilizzabili per il confronto perché i modelli che usano la rete neurale hanno bisogno di un certo numero di errori dei periodi precedenti in input per ottenere la stima in output degli errori futuri.

Il primo confronto è effettuato mediante analisi grafica dei livelli acustici previsti dai tre diversi modelli rispetto a quelli realmente osservati. Sono stati scelti due intervalli di dati particolarmente significativi: il primo va dal periodo 200 al periodo 300, ossia dal 26 Novembre 2007 al 5 Maggio 2008, il secondo va dal periodo 900 al periodo 1000, dal 26 Ottobre 2009 al 3 Febbraio 2010. Si è scelto dunque di analizzare un intervallo di tempo prima e un intervallo dopo rispetto al brusco cambio di trend che è possibile osservare nell'intervallo di tempo tra il periodo 700 e l'800, si veda la Figura III.1. Nelle figure III.10 e III.11 sono osservabili i dati reali e le previsioni dei tre modelli nei due distinti periodi di tempo. Si può notare che, nonostante la media delle misurazioni sia alquanto diversa nei due grafici, i tre modelli nel complesso sono riusciti a stimare in maniera opportuna i livelli acustici. La brusca variazione di trend e la non stazionarietà della serie non ha influito negativamente sulla previsione. Come è normale aspettarsi il modello DD+ANN( $t-1$ ) è quello più veloce nell'adequaresi a fluttuazioni nel livello acustico che interessano un ristretto numero di giorni adiacenti, tuttavia singole e isolate variazioni nell'emissione non possono essere previste da nessuno dei tre modelli.

In particolare possiamo osservare nel primo grafico che i periodi dal 228 al 230 presentano un livello acustico anomalo poiché particolarmente basso: questi infatti sono i giorni 24, 25 e 26 dicembre, caratterizzati dalle festività natalizie. In questi giorni molto particolari possiamo osservare interessanti caratteristiche dei tre modelli: il modello DD-TSA assegna una emissione acustica alta poiché i coefficienti di stagionalità sono quelli relativi a giorni lavorativi infrasettimanali; il modello TSA+ANN( $t-1$ ) è veloce nel seguire la variazione ma solo al periodo 230 l'effetto di riduzione dell'emissione consente alla previsione di avvicinarsi al valore osservato; il modello TSA+ANN( $t-7$ ) risente in ritardo dei tre periodi festivi di bassa emissione, ma questa caratteristica gli consente di avvicinarsi maggiormente al valore reale quando l'effetto della festività si conclude al periodo 231. In generale picchi di emissione isolati, o livelli particolarmente bassi rispetto ai giorni adiacenti restano da considerarsi fluttuazioni casuali non prevedibili.



**Fig. III.10:** Confronto tra la serie storica dei dati reale (linea nera), previsioni DD-TSA (linea rossa), DD+ANN( $t-1$ ) (linea blu) e DD-TSA( $t-7$ ) (linea magenta). È mostrato l'intervallo temporale tra il 200° e il 300° periodo, ossia i giorni dal 26 novembre 2007 al 5 maggio 2008.



**Fig. III.11:** Confronto tra la serie storica dei dati reale (linea nera), previsioni DD-TSA (linea rossa), DD+ANN( $t-1$ ) (linea blu) e DD-TSA( $t-7$ ) (linea magenta). È mostrato l'intervallo temporale tra il 900° e il 1000° periodo, ossia i giorni dal 26 ottobre 2009 al 3 febbraio 2010.

### 3.1.8 Valutazione degli errori di previsione sui dati di calibrazione

L'errore complessivo dei tre modelli può essere valutato come differenza tra il valore realmente osservato e quello previsto in ciascun intervallo di tempo. In particolare le prestazioni sono confrontate considerando l'errore  $e_t^*$  per il modello DD-TSA, in accordo alla formula  $e_t^* = A_t - \hat{F}_t$ , e l'errore  $\Delta_t$  per i due modelli ibridi, in accordo alla formula  $\Delta_t = A_t - (\hat{F}_t + \hat{e}_t)$ .

È dunque possibile ottenere un confronto quantitativo tra i modelli proposti analizzando l'andamento dell'errore totale durante la fase di previsione.

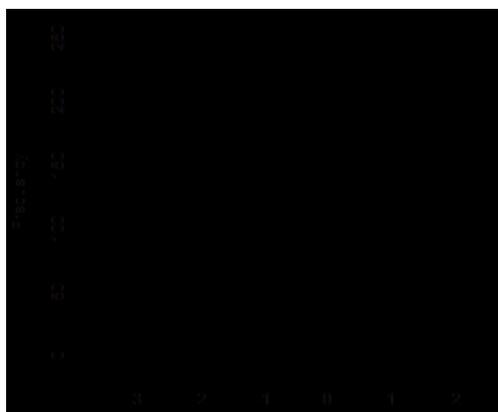
Nella tabella III.8 sono mostrate le statistiche riassuntive dell'errore commesso dai tre modelli durante 1087 periodi di calibrazione. La media è molto bassa per tutti e tre i modelli e prossima allo zero. La superiorità previsionale dei due modelli ibridi può essere vista grazie alla ben più bassa deviazione standard rispetto al modello DD-TSA.

L'ipotesi di distribuzione normale degli errori è plausibile per tutti e tre i modelli: gli indici di curtosi e simmetria si discostano in modo trascurabile dallo zero. L'ipotesi di normalità degli errori può essere positivamente valutata anche grazie agli istogrammi e ai diagrammi quantile-quantile (Q-Q plot) mostrati nelle figure III.12, III.13 e III.14. Vediamo che solo le code delle distribuzioni a volte si discostano da una perfetta curva gaussiana.

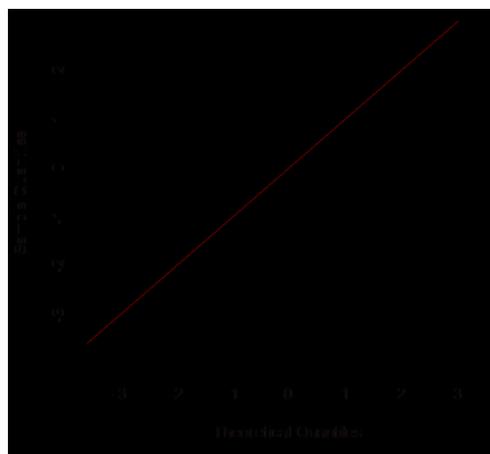
**Tab. III.8:** Statistiche riassuntive degli errori valutati su 1087 dati di calibrazione.

Modello	Media [dBA]	Dev.Std. [dBA]	Mediana [dBA]	skew	kurt
DD-TSA	0.01	0.90	0.15	-0.58	-0.01
DD-ANN( $t-1$ )	-0.02	0.52	-0.04	-0.13	2.73
DD-ANN( $t-7$ )	0.01	0.63	0.02	-0.34	4.13

Il digramma quantile-quantile confronta i quantili del campione osservato con quelli di una distribuzione teorica, nel nostro caso quella normale. Quando i punti si dispongono secondo la bisettrice, la distribuzione indagata si avvicina a quella teorica. Nel caso in esame sia gli errori del DD-TSA che dei due modelli ibridi mostrano variazioni trascurabili dai quantili teorici, solo in pochi casi le code delle distribuzioni con i punti che le rappresentano sono alquanto normali dalla bisettrice.

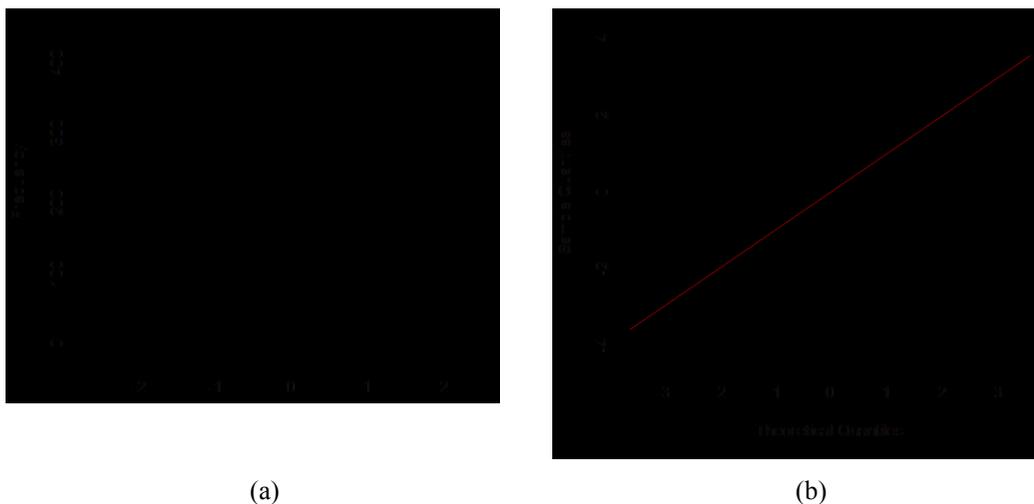


(a)

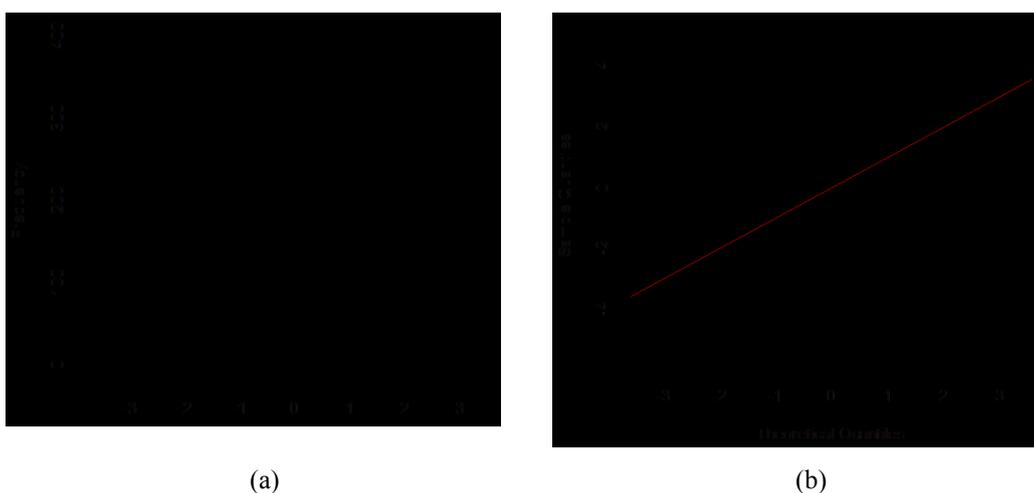


(b)

**Fig. III.12:** (a) Istogramma di frequenza degli errori di previsione commessi dal modello DD-TSA applicato a 1087 dati di calibrazione. (b) Diagramma quantile-quantile utile per valutare la normalità della distribuzione di questi errori.



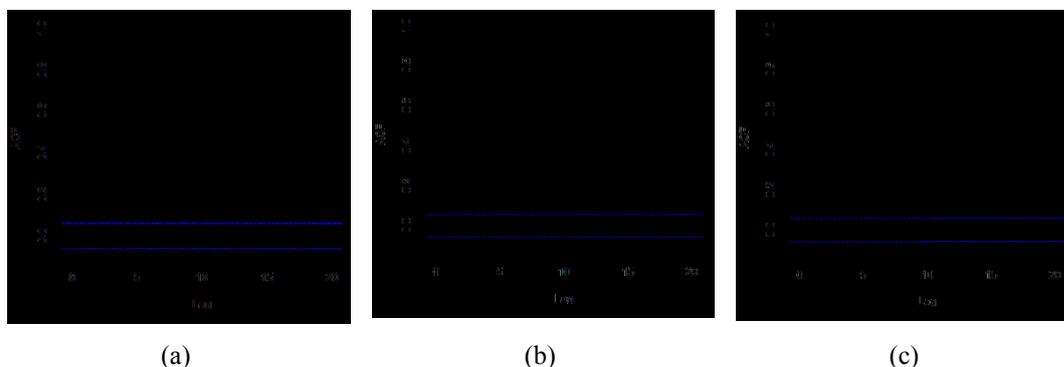
**Fig. III.13:** (a) Istogramma di frequenza degli errori di previsione commessi dal modello DD-ANN( $t-1$ ) applicato a 1087 dati di calibrazione. (b) Diagramma quantile-quantile utile per valutare la normalità della distribuzione di questi errori.



**Fig. III.14:** (a) Istogramma di frequenza degli errori di previsione commessi dal modello DD-ANN( $t-7$ ) applicato a 1087 dati di calibrazione. (b) Diagramma quantile-quantile utile per valutare la normalità della distribuzione di questi errori.

L'autocorrezione degli errori è stata valutata con l'ausilio dei correlogrammi riportati in figura III.15. Questo test verifica se la sequenza degli errori presenta una autocorrelazione e dunque se gli stessi possono essere dovuti solo a fluttuazioni casuali. Questa è una fondamentale verifica della capacità dei modelli adottati di estrarre tutta l'informazione riguardo alla dipendenza temporale dei dati osservati. Una correlazione elevata è stata ancora rilevata negli errori del modello DD-TSA: in questa serie c'è ancora molta informazione che le reti neurali possono sfruttare. Il modello DD+ANN( $t-1$ ) mostra le migliori capacità previsionali: l'autocorrelazione residua è particolarmente bassa.

La serie relativa al modello DD+ANN( $t-7$ ) mostra una ridotta autocorrelazione residua per i valori di ritardo più bassi. Nella tabella III.9 sono mostrati i valori di autocorrelazione calcolati per i due ritardi più significativi rispetto alla serie storica originaria: 7 e 14 giorni. Dunque è possibile notare che i due modelli ibridi presentano valori molto bassi di autocorrelazione residua negli errori di previsione.



**Fig. III.15:** Correlogramma degli errori di previsione calcolati su 1087 dati di calibrazione: (a) applicazione del modello DD-TSA; (b) applicazione del modello DD-ANN( $t-1$ ); (c) applicazione del modello DD-ANN( $t-7$ ). Il valore dell'autocorrelazione è riportato in funzione del ritardo considerato.

**Tab. III.9:** Valori dell'autocorrelazione per gli errori di previsione calcolati applicando i modelli ai 1087 dati. I valori riportati sono relativi ai due ritardi più significativi.

	DD-TSA	DD-ANN( $t-1$ )	DD-ANN( $t-7$ )
ritardo 7 giorni	0.662	-0.033	-0.063
ritardo 14 giorni	0.589	0.066	-0.042

I valori delle metriche MPE e CVE sono riportati nella tabella III.10: mostrano l'ottima prestazione previsionale del modello DD-TSA in termini di errore medio percentuale. Nonostante il fatto che la serie analizzata sia fortemente non stazionaria a causa della brusca variazione di media presente tra il periodo 700 e l'800, tutti e tre i modelli sono riusciti a fornire previsioni non affette da distorsioni manifeste: la previsione dei modelli in media non sovrastima né sottostima i dati reali. La metrica CVE mostra che, come era lecito aspettarsi, il modello che disperde meno la previsione intorno al dato osservato è il TSA+ANN( $t-1$ ).

**Tab. III.10:** Valori delle metriche di errore calcolate dopo l'applicazione dei tre modelli a 1087 dati della serie di calibrazione.

Modello	MPE	CVE
DD-TSA	0.000	0.012
DD-ANN( $t-1$ )	-0.030	0.007
DD-ANN( $t-7$ )	0.012	0.009

### 3.1.8 Analisi di prestazione dei modelli

Il performance test è la vera prova del modello su dati mai elaborati prima: dopo aver nelle fasi precedenti calibrato tutti i parametri, coefficienti e pesi della rete si immettono gli ingressi nel motore inferenziale costruito (nel nostro caso gli ingressi sono le emissioni acustiche nei periodi pregressi) e si valuta la previsione fornita rispetto ai dati reali osservati. Dunque nel modello ibrido si introducono prima le emissioni acustiche nei giorni precedenti a quelli per i quali si desidera una previsione e successivamente gli errori generati dal modello DD-TSA.

Per il performance test usiamo i livelli acustici misurati e gli errori generati durante le previsioni DD-TSA dal periodo 1101 al 1200 (15 maggio 2010 al 22 agosto 2010).

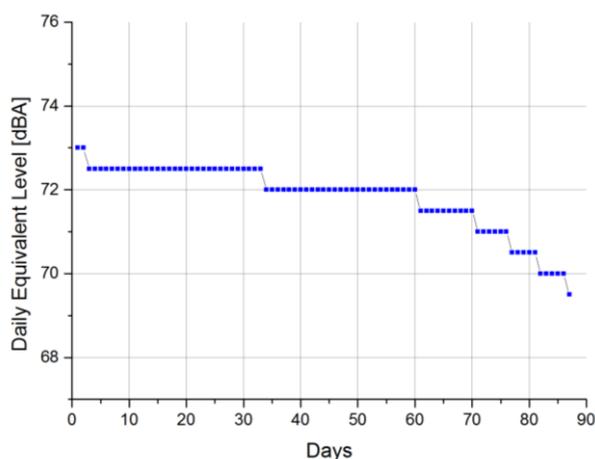
È opportuno ribadire che questi dati non sono stati usati per calibrare i coefficienti e i parametri del modello DD-TSA né per aggiornare i pesi dell'ANN dunque costituiscono una buona serie per capire l'effettiva potenza previsionale del modello.

La tabella III.11 mostra alcune statistiche riassuntive degli 87 livelli acustici misurati tra Maggio e Agosto 2010. Queste misurazioni evidenziano che la media dell'emissione giornaliera è alta in assoluto, superando i 71 dBA. È interessante notare che la media dell'emissione acustica in questi 87 giorni non è molto diversa da quella dei 1087 giorni di calibrazione. Gli indici di asimmetria e curtosi sono molto vicini a quelli caratteristici di dati provenienti da una distribuzione normale.

Il grafico di figura III.16 mostra, ad esempio, che in più di 30 giorni su 87 si sono superati i 72 dBA come livello acustico.

**Tab. III.51:** Statistiche riassuntive del livello equivalente misurato durante gli 87 giorni del set di dati usato per il performance test.

Media [dBA]	Dev. Std. [dBA]	Mediana [dBA]	Min [dBA]	Max [dBA]	Skew.	Kurt.
71.84	0.79	72.0	69.5	73.0	-1.13	0.45



**Fig. III.16:** Livello acustico equivalente giornaliero misurato nell'intervallo temporale del performance test diagrammato in ordine decrescente di magnitudo. L'asse x riporta il numero di giorni nei quali il corrispondente livello di rumorosità è superato.

E' stato applicato agli 87 dati il test statistico di Ljung-Box (LB) e i risultati sono mostrati in tabella III.12: il basso valore del  $p$ -value, ossia la ridotta probabilità di osservare il campione se l'ipotesi nulla fosse vera, indica che l'ipotesi di assenza di autocorrelazione anche in queste 87 misurazioni può essere rifiutata.

Sono stati effettuati sugli 87 livelli acustici giornalieri anche i test di linearità Lee-White-Granger (LWG) e Terasvirta-Lin-Granger (TLG). I risultati livelli di probabilità, riportati nella tabella III.13, sono sufficientemente alti da consentire di accettare l'ipotesi di linearità della serie osservata. Il valore del  $p$ -value ottenuto dai test di Dickey-Fuller e Phillips-Perron, si veda la tabella III.14, non consente di rifiutare l'ipotesi nulla della presenza di radici unitarie nel processo: è dunque molto probabile che la serie storica sia non-stazionaria.

**Tab. III.12:** Test di Ljung-Box applicato alle 87 misure del performance test.

Test	$\chi^2$	$d$	$p$ -value
Ljung-Box	137.7768	20	$< 2.2 \times 10^{-16}$

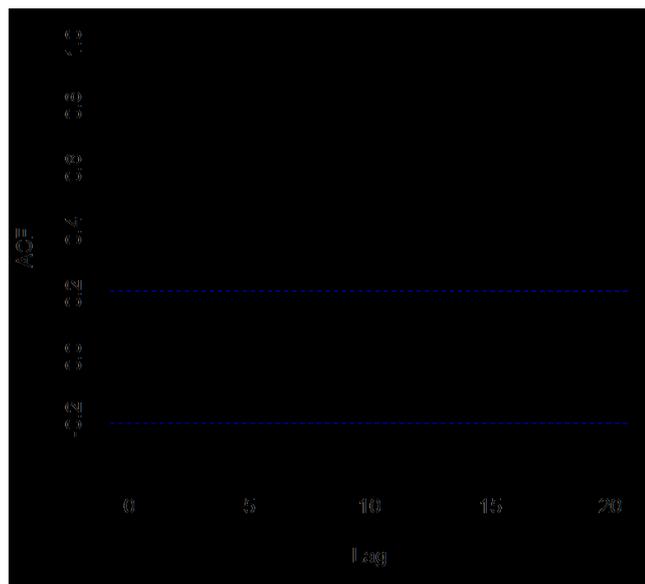
**Tab. III.13:** Test di linearità di Lee-White-Granger (LWG) e Terasvirta-Lin-Granger (TLG) applicati alle 87 misure del performance test.

Test	Statistica del test	$df$	$p$ -value
LWG	10.9822	2	0.004123
TLG	6.4167	2	0.04042

**Tab. III.14:** Test di stazionarietà di Dickey-Fuller e Phillips-Perron applicati alle 87 misure del performance test.

Test	Statistica del test	Lag	$p$ -value
Augmented Dickey-Fuller	-6.6307	4	0.01
Phillips-Perron	-8.1747	3	0.01

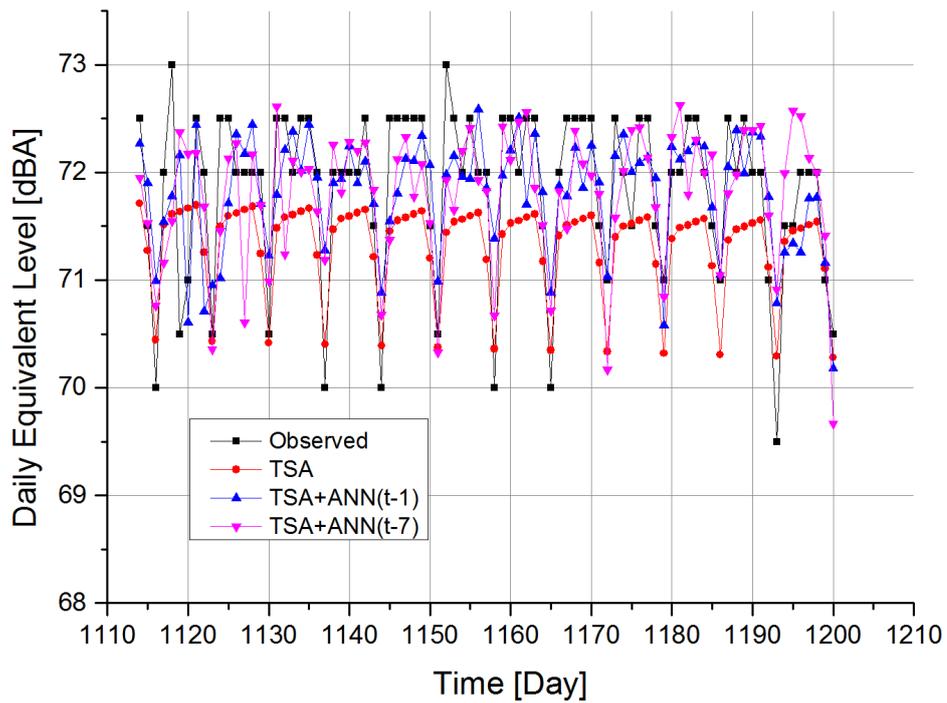
Il grafico di figura III.17 mostra che gli 87 dati del performance test hanno una alta autocorrelazione statisticamente significativa per un lag pari a 7: come era naturale aspettarsi anche questi dati di traffico veicolare sono fortemente influenzati dalla densità del veicoli circolanti, numerosità dei veicoli che varia notevolmente a seconda del giorno della settimana considerato.



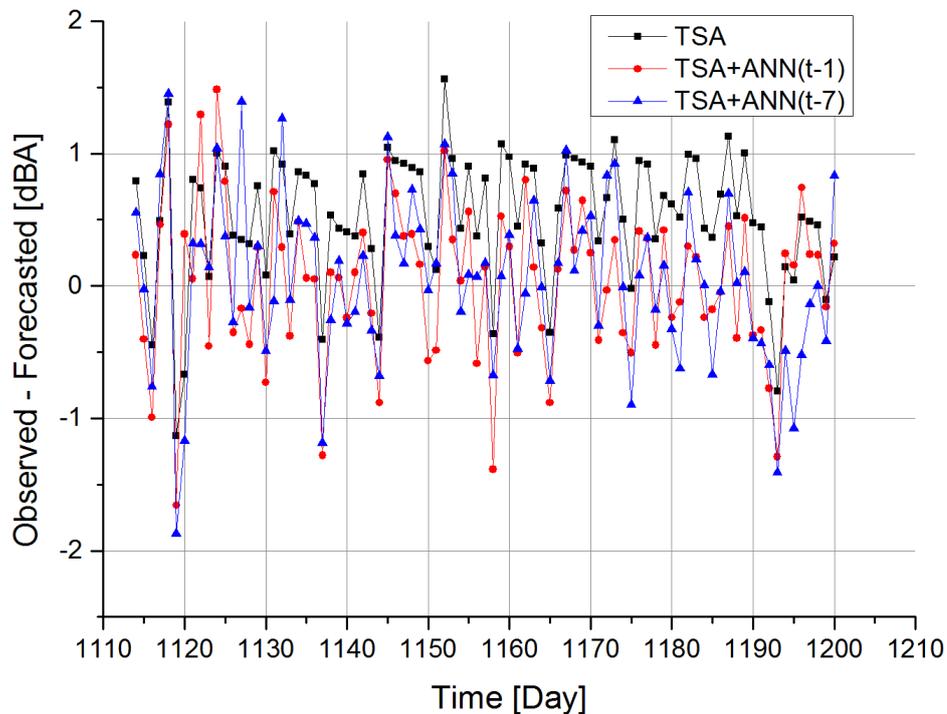
**Fig. III.17:** Correlogramma del set di dati usato per il performance test.

Il confronto tra le emissioni acustiche realmente osservate e i valori previsti dai tre modelli proposti può dare fondamentali informazioni sulle attitudini previsionali su dati futuri non elaborati dai modelli in fase di calibrazione. In figura III.18 è facile osservare che il modello DD-TSA sottostima il valore reale di emissione acustica in tutti gli 87 periodi del performance test. Per correggere la tendenza potrebbe essere consigliabile ricalcolare il trend tagliando parte dei periodi più vecchi della serie di calibrazione: per serie storiche non stazionarie questa tecnica è utilmente applicabile. La periodicità settimanale della serie è riprodotta con buona approssimazione, tuttavia alcuni picchi di emissione non sono previsti adeguatamente dal modello a causa della natura completamente casuale di questi eventi. In dettaglio è possibile vedere al periodo 1119 un livello di emissione inaspettatamente basso che non viene previsto da nessuno dei tre modelli: infatti questo in Italia è un giorno di festività nazionale (festa della Repubblica). Il periodo successivo si nota una ripresa graduale del normale traffico con un livello di emissione in risalita ma ancora basso rispetto alla media del periodo: in questo caso il modello DD+ANN( $t-1$ ), essendo il più veloce a seguire le brusche e inattese variazioni, riesce ad avvicinarsi al dato reale osservato. L'effetto di riduzione dovuto al basso valore osservato durante il 2 giugno sul livello previsto dal modello DD+ANN( $t-7$ ) si manifesta solo dopo sette giorni, con una conseguenza negativa sull'errore di previsione per il modello in quel periodo. In generale per risolvere il problema delle previsioni nei giorni festivi, sarebbe opportuno inserire nella rete neurale un input del tipo "flag" per distinguere i giorni festivi da quelli lavorativi.

In figura III.19 sono mostrati gli errori di previsione commessi dai tre modelli negli 87 periodi del performance test. Si può notare che gli errori del modello DD-TSA non risultano casuali ma risentono ancora di una periodicità settimanale che non è stata adeguatamente riprodotta dal modello. Inoltre la maggior parte degli errori sono positivi, ulteriore conferma che il modello sottostima in tutto il periodo i dati misurati. I plot dei modelli ibridi mostrano una dispersione maggiore intorno alla zero ma tuttavia distribuita più equamente tra valori positivi e negativi.



**Fig. III.18:** Confronto tra la serie storica dei dati reale (linea nera) e: previsioni DD-TSA (linea rossa), DD+ANN( $t-1$ ) (linea blu), DD-TSA( $t-7$ ) (linea magenta). L'intervallo temporale è relativo ai periodi tra il 28 maggio 2010 e il 22 agosto 2010.



**Fig. III.19:** Errori di previsione commessi dai tre modelli durante gli 87 giorni del performance test. In particolare: DD-TSA (linea nera), DD+ANN( $t-1$ ) (linea rossa) e DD-TSA( $t-7$ ) (linea blu).

### 3.1.9 Valutazione e analisi degli errori sul set di dati di validazione

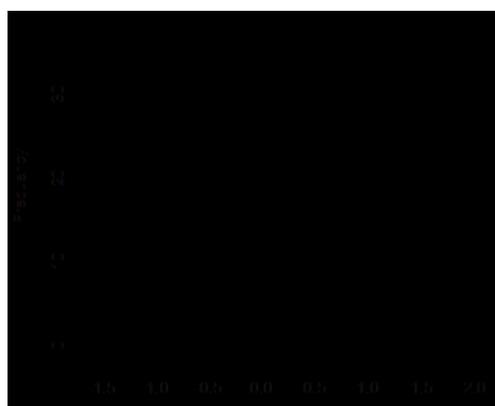
Nella tabella III.15 sono mostrate le statistiche riassuntive dell'errore di previsione commesso dai tre modelli durante gli 87 periodi del performance test. In particolare gli errori del modello DD-TSA sono stati valutati secondo la formula III.4, mentre gli errori dei due modelli ibridi con ANN in cascata sono stati calcolati in accordo con la formula III.5. riportate anche successivamente.

La media e la mediana dell'errore per il modello DD-TSA sono diverse da zero a causa della sottostima rispetto ai dati osservati. Per i modelli ibridi invece sia la media che la mediana sono molto basse e prossime allo zero. Tuttavia, come riscontrato anche dall'analisi grafica della figura III.19, i due modelli ibridi mostrano una deviazione standard dell'errore più elevata rispetto al semplice modello DD-TSA.

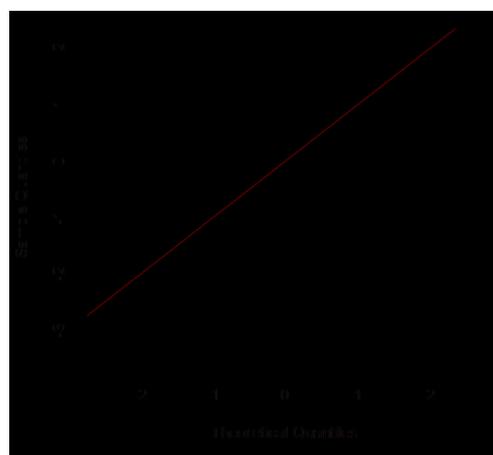
L'ipotesi di distribuzione normale degli errori è plausibile per i due modelli ibridi: gli indici di curtosi e simmetria si discostano in modo trascurabile dallo zero. L'ipotesi di normalità degli errori può essere positivamente valutata anche grazie agli istogrammi e ai diagrammi quantile -quantile (Q-Q Plot) mostrati nelle figure 21 e 22. Inoltre anche i risultati del test di Jarque-Bera mostrati nella tabella III.16 non consentono di rifiutare l'ipotesi di distribuzione normale degli errori per i due modelli ibridi.

**Tab. III.15:** Statistiche degli errori di previsione valutati sugli 87 dati del performance test.

Modello	Media [dBA]	Dev.Std. [dBA]	Mediana [dBA]	skew	kurt
DD-TSA	0.53	0.49	0.53	-0.93	0.98
DD-ANN( $t-1$ )	0.04	0.59	0.12	-0.33	0.34
DD-ANN( $t-7$ )	0.05	0.63	0.08	-0.23	0.29



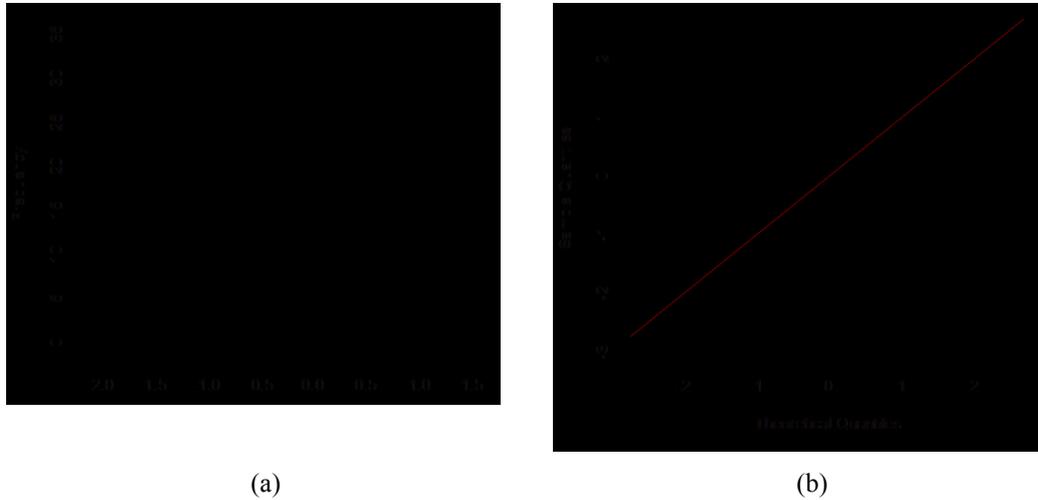
(a)



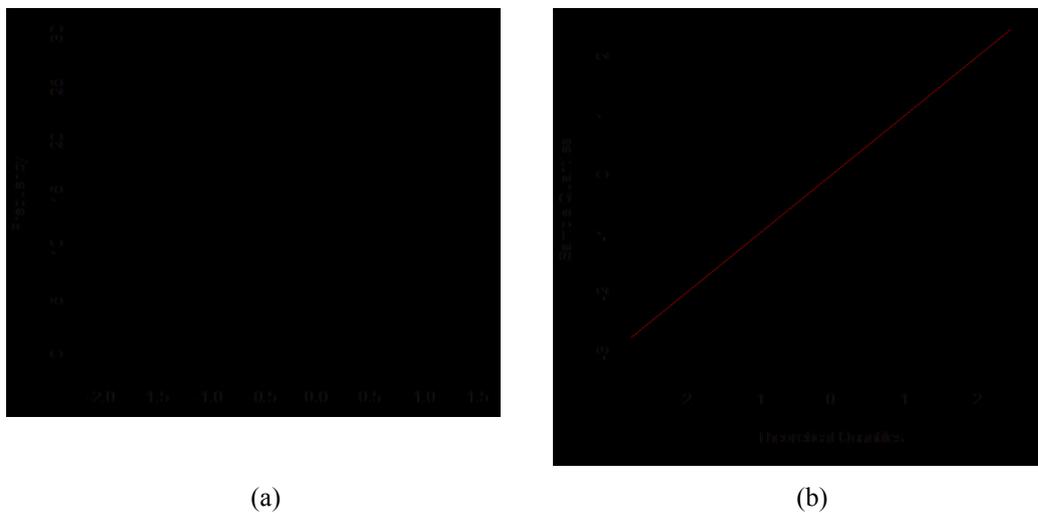
(b)

**Fig. III.20:** (a) Istogramma di frequenza degli errori di previsione commessi dal modello DD-TSA applicato agli 87 dati del performance test. (b) Diagramma quantile-quantile utile per valutare la normalità della distribuzione di questi errori.

La verifica di distribuzione normale degli errori per il modello DD-TSA è meno probante ma comunque non deve essere abbandonata come mostrato sia dagli indici di curtosi e simmetria non eccessivamente elevati, sia dall'istogramma e dal Q-Q Plot di figura III.20 che non si discostano eccessivamente da un andamento normale.



**Fig. III.21:** (a) Istogramma di frequenza degli errori di previsione commessi dal modello DD-ANN( $t-1$ ) applicato agli 87 dati del performance test. (b) Diagramma quantile-quantile utile per valutare la normalità della distribuzione di questi errori.



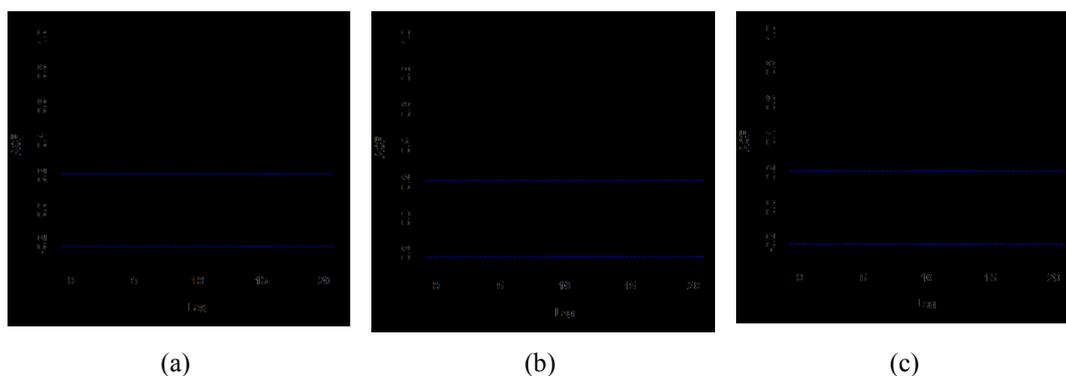
**Fig. III.22:** (a) Istogramma di frequenza degli errori di previsione commessi dal modello DD-ANN( $t-7$ ) applicato agli 87 dati del performance test. (b) Diagramma quantile-quantile utile per valutare la normalità della distribuzione di questi errori.

**Tab. III.16:** Risultati del test di normalità Jarque-Bera applicato agli errori di previsione dei tre modelli, errori commessi negli 87 giorni del performance test.

Modello	Statistiche del test	Gradi di libertà	<i>p</i> -value
DD-TSA	17.1512	2	0.00019
DD-ANN( <i>t</i> -1)	2.2952	2	0.31740
DD-ANN( <i>t</i> -7)	1.2787	2	0.52760

L'andamento della funzione di autocorrelazione per gli errori durante la fase di performance test è stato riportato nella figura III.23. Si ricorda che se nella serie degli errori è presente un'alta autocorrelazione residua, probabilmente i modelli adottati non sono stati in grado di estrarre tutto il contenuto informativo dovuto alle dipendenze temporali nei dati. In figura III.23 è possibile notare che sia il modello DD-TSA che il modello DD+ANN(*t*-1) presentano ancora una autocorrelazione settimanale (lag uguale a sette) statisticamente significativa degli errori di previsione. Tuttavia questa autocorrelazione è molto più bassa rispetto a quella presente nella serie originale per lo stesso lag che era pari a circa 0.7.

Il modello DD+ANN(*t*-7) ha mostrato invece di non avere residui di autocorrelazione significativa nel dataset degli errori di previsione. Anche i valori della funzione di autocorrelazione degli errori per lag significativi pari a 7 e 14 periodi sono molto bassi come mostrato nella tabella III.17.



**Fig. III.23:** Correlogramma degli errori di previsione calcolati sugli 87 dati del performance test: (a) applicazione del modello DD-TSA; (b) applicazione del modello DD-ANN(*t*-1); (c) applicazione del modello DD-ANN(*t*-7). Il valore dell'autocorrelazione è diagrammato in funzione del ritardo considerato.

**Tab. III.17:** Valori dell'autocorrelazione per gli errori di previsione calcolati applicando i modelli agli 87 dati del performance test. I valori riportati sono relativi ai due ritardi più significativi.

	DD-TSA	DD-ANN( <i>t</i> -1)	DD-ANN( <i>t</i> -7)
ritardo 7 giorni	0.356	0.411	0.097
ritardo 14 giorni	0.243	0.277	0.121

I valori di MPE e CVE, riportati nella tabella III.18, mostrano le buone prestazioni dei due modelli ibridi in termini di errore medio percentuale, anche la dispersione intorno alla media per i due modelli con ANN in cascata è molto bassa.

Invece il valore elevato dell'indice MPE per il modello DD-TSA mostra che con questa calibrazione non si è riusciti a cogliere il trend del periodo di performance test e si è resa manifesta una sottostima della previsione rispetto ai dati reali osservati.

**Tab. III.18:** Valori delle metriche di errore calcolate dopo l'applicazione dei tre modelli agli 87 dati del performance test.

Modello	MPE	CVE
DD-TSA	0.727	0.010
DD-ANN( $t-1$ )	0.043	0.008
DD-ANN( $t-7$ )	0.070	0.009

### 3.1.10 Discussione sui risultati ottenuti

In questo capitolo è stata accuratamente analizzata dal punto di vista statistico una serie storica di dati di livello acustico equivalente misurati nella città di Messina, in Italia. La sorgente di rumore prevalente è quella del traffico veicolare cittadino aggiunto al rumore antropico dovuto al porto commerciale.

Le tecniche classiche di previsione del rumore prodotto dalle attività antropiche prevedono la conoscenza di diverse variabili. In particolare per una accurata previsione del traffico veicolare sono necessarie informazioni quantitative riguardanti il numero di veicoli in transito, la velocità media e la tipologia degli stessi. Non meno importanti al fine di prevedere correttamente l'emissione acustica sono la corretta valutazione e misurazione di diverse variabili ambientali come ad esempio la temperatura e l'umidità dell'aria.

Nell'analisi qui presentata si mostra che, quando l'emissione acustica è fortemente legata ad attività antropiche regolari, anche il livello acustico ambientale nel tempo si mostra estremamente periodico. Se questo avviene si può effettuare una previsione dei livelli acustici molto accurata conoscendo solo i livelli di rumore misurati in un intervallo di tempo sufficientemente ampio.

La serie storica studiata è autocorrelata, lineare e non stazionaria dato che mostra una brusca e accentuata variazione della media in un ristretto intervallo temporale.

Per prevedere il livello acustico sono stati implementati e confrontati tre diversi modelli previsionali inizialmente calibrati grazie ad un set di dati composto da 1100 misurazioni.

Il primo modello DD-TSA si basa su tecniche di decomposizione deterministica per l'analisi delle serie storiche e consente di estendere la previsione nel futuro per molti intervalli di tempo successivi a quelli della fase di calibrazione. Questa tecnica è stata descritta dettagliatamente e applicata con successo nel capitolo primo.

Gli altri due modelli sfruttano in una fase iniziale il modello DD-TSA, fase seguita poi dall'utilizzo in cascata di un predittore basato su di una rete neurale artificiale che fornisce in output la stima dell'errore di previsione commesso dal modello DD-TSA.

In particolare il modello DD+ANN( $t-1$ ) fornisce una previsione molto accurata del livello acustico di un solo periodo successivo a quello nel quale è possibile calcolare l'errore di previsione del DD-TSA; ossia è possibile ottenere una previsione per un istante di tempo successivo rispetto all'ultimo nel quale si conosce un dato reale.

Il modello DD+ANN( $t-7$ ), pagando un piccolo peggioramento delle performance previsionali, fornisce la possibilità di una previsione estesa a ben sette periodi successivi: ad esempio è possibile prevedere con grande accuratezza l'emissione acustica ad una settimana di distanza dall'ultima misurazione effettuata.

Nell'ultima parte dello studio è stata implementata una fase di performance test confrontando le capacità previsionali dei tre modelli proposti utilizzando 87 dati della serie storica analizzata non usati nella fase di calibrazione. Le previsioni del modello DD-TSA sono state in generale capaci di riprodurre fedelmente l'andamento periodico dei dati, tuttavia tale tecnica è stata affetta da una costante sottostima dei livelli acustici realmente osservati. È probabile che per migliorare la previsione, vista la forte non stazionarietà della serie, i parametri del trend si dovrebbero calcolare su periodi non molto lontani nel tempo per evitare l'effetto di variazioni in media molto forti. Il modello DD+ANN( $t-1$ ) è stato quello più veloce nel seguire le fluttuazioni di breve periodo della serie osservata, insieme all'altro modello ibrido ha dato prova di ottime capacità previsionali: la differenza tra i due modelli si sintetizza nel diverso orizzonte di previsione. Il performance test ha comunque evidenziato che fluttuazioni nel livello acustico isolate e casuali non possono essere previste con accuratezza da nessuno dei tre modelli proposti.

In futuro si vuole esplorare la possibilità di utilizzare come primo modello di analisi delle serie storiche un modello lineare stocastico del tipo ARMA o ARIMA, seguito in cascata da un modello tipo rete neurale ricorsiva per la previsione dell'errore.



**Modelli di Poisson non omogenei  
applicati a dati acustici**



## 4.1 Analisi di dati di rumorosità aeroportuale usando un modello di Poisson non omogeneo con un *change-point*

Come già detto in precedenza l'inquinamento acustico può causare serie patologie agli individui che vivono o passano molte ore in ambienti ad alta rumorosità (si veda ad esempio [88-90]). Tra gli effetti nocivi di questo tipo di inquinamento ci sono la riduzione dell'udito, i disturbi del sonno e gravi patologie cardiovascolari. Queste ultime possono verificarsi dopo lunghe esposizioni alla rumorosità ambientale anche causata dal traffico veicolare. Per tali ragioni è molto importante cercare di prevedere l'andamento nel tempo di questo tipo di inquinanti. Tuttavia in molti contesti è sufficiente anche riuscire a studiare e monitorare l'andamento nel tempo dei superamenti di alcune soglie critiche di inquinamento. Infatti spesso l'effetto degli agenti nocivi sull'organismo umano segue comportamenti non lineari: superati alcuni valori critici il danno per l'organismo è sensibilmente superiore. Ci sono diverse tecniche per misurare il livello acustico; nel caso di una rumorosità continua, come è il rumore da traffico veicolare, la metodologia più usata consiste nel calcolare l'energia media equivalente del suono, valutata in un periodo  $T$  e pesando i valori ottenuti mediante la curva di ponderazione  $A$ ; questa misura specialistica è denotata con " $L_{Aeq,T}$ ". Quando ci sono eventi particolari come il decollo di un aereo o il passaggio di un treno, allora oltre all' $L_{Aeq,T}$  può essere usato anche l' $L_{Amax}$ . In particolare il  $L_{Aeq,T}$  è calcolato in accordo alla seguente formula:

$$L_{Aeq,T} = 10 \log \left[ \frac{1}{T} \int_0^T \frac{p_A^2(t)}{p_0^2} dt \right], \quad (IV.1)$$

nella quale  $p_A^2(t)$  e  $p_0^2$  rappresentano rispettivamente il quadrato della pressione ponderata  $A$  al periodo  $t$  e il quadrato della pressione di riferimento. Invece  $L_{Amax}$  è il massimo valore del livello di pressione sonora ponderato  $A$  raggiunto durante un intervallo di tempo di riferimento [91].

Generalmente le tecniche di previsione della rumorosità acustica possono tentare di descrivere e modellare vari aspetti dei fenomeni coinvolti. Più in generale in [5] sono state studiate varie metodologie per descrivere il rumore da traffico veicolare, sia sfruttando tecniche statistiche sia tenendo conto di aspetti dinamici. Tra le tecniche di modellazione più utilizzate si possono ricordare la CoRTN (calcolo della rumorosità del traffico veicolare) indicata dalla regolamentazione del Regno Unito, che è stata sviluppata nel 1975 [92] e successivamente modificata nel 1988 [93]. Negli Stati Uniti è stata usata prima la vecchia versione del modello di rumorosità da traffico FHWA [94] e successivamente una versione aggiornata [95].

La modellazione proposta in questo capitolo ha lo scopo di conoscere la probabilità che il livello di rumorosità possa eccedere una soglia stabilita in un intervallo temporale di interesse. Risulta anche di interesse stimare il numero medio di volte che una soglia viene superata in un dato intervallo di tempo. Inoltre è particolarmente interessante rispondere a questo genere di domande in aree vicine a zone aeroportuali. Per modellare questo genere di fenomeni e rispondere ai quesiti proposti, sarà usato un processo di Poisson non omogeneo. Di particolare interesse è anche il fatto che il set di misurazioni usato ha peculiari caratteristiche mostrando un repentino cambio della media dei valori nell'intervallo di tempo considerato. A tal proposito è stata implementata la cosiddetta metodologia del "*change-point*". Questo tipo di bruschi "cambi" descritti dal modello implicano che qualche particolare evento può essere accaduto modificando l'andamento delle misurazioni. Dunque è possibile avere livelli di rumorosità più alti (o bassi) prima del *change-point*, e dopo questo periodo temporale livelli più bassi (o alti).

Analizzando i dati, una volta individuato un *change-point*, è possibile indagare le cause del cambiamento nelle misurazioni. Modelli analoghi con *change-points* sono stati usati in diverse discipline; nel caso di applicazioni ambientali [97,98] si è studiato l'andamento di inquinanti gassosi, in [99] invece si sono applicate queste tecniche alla previsione dell'abbondanza di specie marine. Altre applicazioni e studi correlati sono stati nel settore della epidemiologia [100] e negli studi di genetica [101], medicina e finanza.

Dato che nelle funzioni che descrivono il modello sono presenti diversi parametri, questi ultimi per poter ottenere un risultato utile devono essere stimati: tale stima può essere ottenuta sia usando tecniche della statistica generica [102-104], sia usando tecniche bayesiane [105]. Nell'approccio generico la stima dei parametri può essere fatta usando la massimizzazione della funzione di verosimiglianza. Con le metodologie bayesiane invece i parametri delle funzioni saranno stimate mediante un algoritmo basato su catene di Markov e estrazioni Monte Carlo (MCMC) [106]. Di seguito verrà descritto il modello teorico ipotizzato con e senza *change-points*; successivamente tale modellazione verrà applicata al set di livelli acustici misurati in prossimità dell'aeroporto internazionale di Nizza Costa Azzurra (Francia). È lo stesso set di livelli orari utilizzato nel secondo capitolo: in generale quando la previsione puntuale del livello di inquinamento non è soddisfacente si può tentare, con questo nuovo approccio di seguito presentato, di prevedere almeno i superamenti di una certa soglia stabilità.

In questo capitolo si utilizzeranno dati acquisiti presso l'aeroporto internazionale di Nizza (Francia); le misurazioni erano disponibili con una base dei tempi di 0.5 secondi e successivamente sono state mediate usando l'equazione IV.1 con  $T$  corrispondente ad un'ora. Lo scopo è quello di ottenere una modellazione dell'andamento dei livelli di rumorosità nei pressi di un aeroporto. A differenza delle metodologie usate nei capitoli precedenti, adesso lo scopo non sarà quello di ricostruire i valori del livello acustico in funzione del tempo, ma ci si concentrerà sugli istanti di tempo nei quali il livello acustico supererà delle soglie limite stabilite in precedenza.

#### 4.1.1 Descrizione del modello matematico

I modelli di Poisson non omogenei [107,108] sono stati usati per studiare diverse problematiche in molti campi della scienza [109,110]. Il modello qui proposto può essere descritto come segue: siano  $S \geq 1$  e  $L > 0$  numeri naturali e reali che rappresentano rispettivamente il totale delle osservazioni effettuate (misure di livello) e la soglia di interesse. Si consideri il numero naturale  $K \geq 0$  come il numero di volte in  $[0, S]$  che la soglia  $L$  è stata superata dal livello di rumorosità. Indichiamo con  $N = \{N_t : t \geq 0\}$  il processo stocastico tale che  $N_t$  sia il numero di volte che il livello di rumorosità ha superato la soglia  $L$  nell'intervallo di tempo  $[0, t], t \geq 0$ . Si assuma che  $N$  sia un processo stocastico con rateo di accadimento  $\lambda(t) > 0$  e funzione media  $m(t) = \int_0^t \lambda(s) ds$ , con  $t \geq 0$ . Nello specifico per  $t, s \geq 0$ , e  $k = 0, 1, 2, \dots$ ,

$$P(N_{t+s} - N_t = k) = \frac{[m(t+s) - m(t)]^k}{k!} \exp(-[m(t+s) - m(t)]), \quad (\text{IV.2})$$

Si indichi con  $h_1, h_2, \dots, h_k$  gli istanti di tempo (ore in questo caso) nelle quali la soglia  $L$  è stata superata nell'intervallo di tempo  $[0, S]$ . con  $\mathbf{D} = \{h_1, h_2, \dots, h_k\}$  si indichi il vettore di questi istanti di tempo.

La modellazione proposta nel seguito implica che  $\lambda(t), t \geq 0$  sia stata scelta del tipo Weibull, ossia  $\lambda(t) = (\alpha/\sigma)(t/\sigma)^{\alpha-1}$ , conseguenzialmente la funzione media è  $m(t) = (t/\sigma)^\alpha, t \geq 0$ ,  $\alpha, \sigma$  appartenenti a  $(0, \infty)$ , si veda ad esempio [111]. Questa particolare funzione per il rateo di accadimento è stata scelta sia tenendo conto della curva di andamento dei superamenti, in particolare della media cumulata  $m(t)$ , sia per il fatto che la funzione di Weibull si adatta molto bene ad un rateo di superamenti che può crescere o decrescere nel tempo: dunque per studiare l'andamento dei superamenti in diversi intervalli temporali questa flessibilità risulta molto utile. In particolare per valori del parametro  $\alpha > 1$  il rateo cresce con il tempo, per  $\alpha < 1$  il rateo decresce e per  $\alpha = 1$  il rateo diventa costante nel tempo e dunque i superamenti saranno descritti da una distribuzione di Poisson omogenea.

Il modello descritto verrà applicato in due varianti: la prima non considera l'utilizzo di *change-points*. Successivamente, vista l'opportunità dell'utilizzo di questa tecnica, si è considerata l'introduzione di un *change-point*  $\tau$  appartenente a  $(0, \infty)$ . Assunta la presenza di un *change-point* vanno ridefinite le funzioni del rateo di accadimento e della media per gli istanti di tempo precedenti e successivi alla variazione. La funzione del rateo di accadimento, per quanto descritto in precedenza, seguirà la seguente forma funzionale di Weibull :

$$\lambda(t) = \begin{cases} \lambda_1(t), & t \leq \tau \\ \lambda_2(t), & t > \tau \end{cases}, \quad (IV.3)$$

nella quale  $\lambda_i(t) = (\alpha_i/\sigma_i)(t/\sigma_i)^{\alpha_i-1}, t \geq 0$ ,  $\alpha_i, \sigma_i$  appartenente a  $(0, \infty), i = 1, 2$ . Dunque la funzione media è data da (vedere ad esempio [97]):

$$m(t) = \begin{cases} m_1(t), & t \leq \tau \\ m_1(\tau) + m_2(t) - m_2(\tau), & t > \tau \end{cases}, \quad (IV.4)$$

nella quale  $m_i(t) = (t/\sigma_i)^{\alpha_i}, i = 1, 2$ .

Quando non è preso in considerazione nessun *change-points*, il vettore dei parametri da stimare è  $\theta = (\alpha, \sigma)$  appartenente a  $\mathbb{R}_+^2$ , ossia è una coppia dell'insieme dei numeri reali positivi. Se invece viene implementato un *change point*, allora il vettore dei parametri sarà  $\theta = (\theta_1, \theta_2, \tau)$  appartenente a  $\mathbb{R}_+^5$ , ossia è una quintupla dell'insieme dei numeri reali positivi, nel quale  $\theta_1 = (\alpha_1, \sigma_1)$  e  $\theta_2 = (\alpha_2, \sigma_2)$  sono i vettori dei parametri del rateo di accadimento quando rispettivamente  $0 \leq t \leq \tau$  e  $\tau < t \leq T$ .

#### 4.1.2 Inferenza statistica

Al fine di stimare i parametri presenti nel modello, sarà usata sia la metodologia frequentista che il punto di vista bayesiano. Seguendo la prima visione la tecnica usata è la massimizzazione della verosimiglianza. Utilizzando il programma Matlab, nel caso senza *change-point*, la stima dei valori che massimizzano la funzione di verosimiglianza del modello risulta relativamente agevole. Quando invece è implementata la tecnica del *change-point*, gli algoritmi di ottimizzazione più potenti, così come quelli implementati nella piattaforma di calcolo Matlab, non sempre riescono a massimizzare una funzione con un elevato numero di parametri; in questi casi può essere spesso usato con successo il metodo bayesiano.

Questi due diversi metodi sono stati estensivamente usati in diversi campi e applicazioni come ad esempio l'inquinamento atmosferico [97,98,110,112]; la genetica [113,114]; il riconoscimento di immagini [115], le neuroscienze [116]; la cristallografia [117]; la biologia evolutivista [118], l'analisi filogenetica [119] e altri.

Quando è usata la metodologia bayesiana, la stima dei parametri è ottenuta attraverso un campionamento ottenuto dalle rispettive distribuzioni a posteriori. Una distribuzione a posteriori di un parametro  $\theta$ , indicata con  $P(\theta|\mathbf{D})$  è del tipo  $P(\theta|\mathbf{D}) \propto L(\mathbf{D}|\theta)P(\theta)$ , nella quale  $P(\theta)$  è la distribuzione a priori di  $\theta$ ,  $L(\mathbf{D}|\theta)$  è la funzione di verosimiglianza del modello.

Poiché si è assunto un modello di Poisson, la funzione di verosimiglianza nel caso senza *change-points* è data da (si veda ad esempio [102,103]):

$$L(\mathbf{D}|\theta) = \left[ \prod_{i=1}^K \lambda(h_i) \right] \exp[-m(S)], \quad (\text{IV.5})$$

nella quale  $\lambda(t)$  e  $m(t)$  sono rispettivamente la funzione del rateo di accadimento e quella della media, con  $t \geq 0$ . Quando è implementato l'uso di un *change-point* (si veda ad esempio [97,98,120]), la funzione di verosimiglianza è della seguente forma:

$$L(\mathbf{D}|\theta) \propto \left[ \prod_{i=1}^{N_\tau} \lambda_1(h_i) \right] \exp -m_1(\tau) \left[ \prod_{i=N_\tau+1}^{N_S} \lambda_2(h_i) \right] \exp -[m_2(S) - m_1(\tau)], \quad (\text{IV.6})$$

nella quale  $\lambda_j(t)$  e  $m_j(t)$  sono rispettivamente la funzione del rateo di accadimento e quella della media,  $j = 1,2$ , con  $t \geq 0$ .

Quando è usato questo punto di vista bayesiano, è assunta l'indipendenza a priori dei parametri. Gli iperparametri della distribuzione a priori sono considerati noti e vengono specificati quando il modello è applicato ai dati.

La scelta del modello che descrive meglio l'andamento dei dati sarà fatta usando sia un confronto grafico, sia metriche quantitative, come la somma delle differenze assolute (SAD) tra il valore reale osservato e quello previsto della media cumulata, sia con la metrica del coefficiente di variazione (CV) di un campione. La somma delle differenze assolute in questa applicazione è definita come:

$$SAD = \sum_{i=1}^K |m(h_i) - \hat{m}(h_i)|, \quad (\text{IV.7})$$

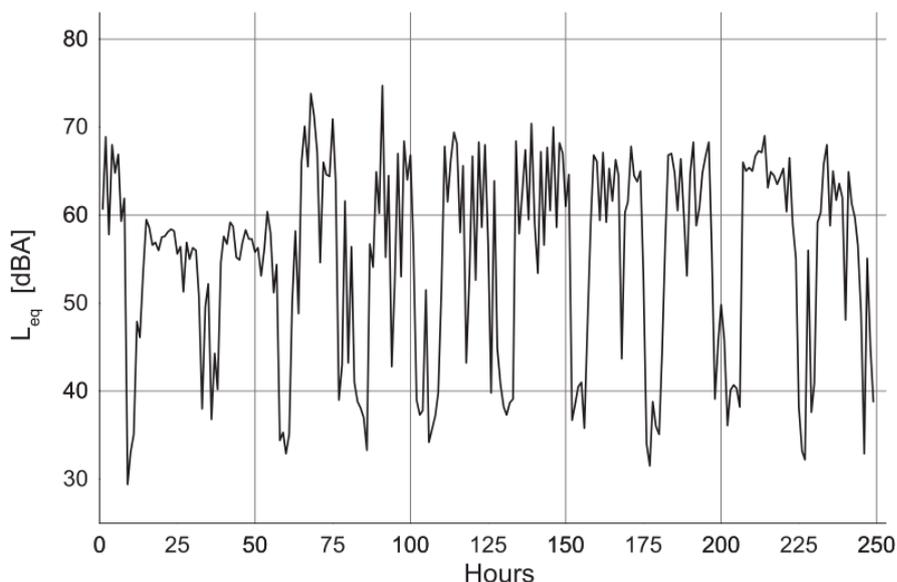
nella quale  $\hat{m}(\cdot)$  è la funzione media quando sono usati i rispettivi parametri stimati, e  $m(\cdot)$  è la media reale osservata.

#### 4.1.3 Applicazione ai livelli di rumorosità dell'aeroporto di Nizza

L'aeroporto di Nizza è situato sulla Costa Azzurra, nel sud della Francia. La località è una ambita meta turistica nella quale un grande numero di villeggianti si reca per trascorrere le proprie vacanze. Durante i periodi festivi, dunque, la regione, e in particolare l'aeroporto, è frequentata da un crescente numero di viaggiatori. Come naturale conseguenza c'è il fatto che un crescente numero di aerei atterra o decolla dall'aeroporto.

Le misurazioni fonometriche considerate qui vanno dalle 16:48 del 21 dicembre 2000 alle 21:48 del primo gennaio 2001, ossia proprio il periodo in concomitanza delle festività di natale e del nuovo anno.

Si ricorda che lo stesso set di dati è stato utilizzato anche nel capitolo secondo. In questo capitolo è stato sfruttato il set di dati completo, costituito da più di un milione di misurazioni, per calcolare i livelli equivalenti relativi alle 249 ore osservate. Tali dati provengono dagli archivi forniti come esempio con il programma “dBTrait” e sono stati utilizzati previa autorizzazione; i relativi livelli orari equivalenti sono stati calcolati direttamente dal programma cambiando i settaggi nei grafici della storia temporale. La figura IV.1 mostra il grafico delle misure orarie relative al periodo considerato.



**Fig. IV.1:** Valori orari dei livelli continui equivalenti di pressione sonora con ponderazione  $A$  misurati all'aeroporto internazionale di Nizza-Costa Azzurra.

È doveroso ricordare che il set di dati analizzato considera la rumorosità totale rilevata al ricevitore e non discrimina i singoli eventi generatori di quel livello sonoro. Dunque sono valutati complessivamente gli effetti di tutte le sorgenti inclusi naturalmente gli aerei che costituiscono la fonte di livello sonoro predominante. Contributi non trascurabili sono dati dai mezzi di trasporto aeroportuali, dalle macchine per la manutenzione degli aerei e per il rifornimento del carburante insieme a tutte le altre attività antropiche connesse ad una zona aeroportuale.

Le misurazioni minime e massime sono rispettivamente di 29.4 dBA e di 74.7 dBA. I dati considerati hanno un valor medio di 55.1 dBA con una deviazione standard di 11.2 dBA. Sono stati in seguito usati due diversi valori per una soglia di riferimento: prima  $L = 55$  dBA e in seguito  $L = 60$  dBA. Durante il periodo di osservazione ci sono state 157 ore e 98 ore nelle quali le due soglie 55 dBA e 60 dBA sono state rispettivamente superate. La marcata differenza tra il livello massimo e minimo misurato, è dovuta al fatto che durante le ore notturne l'aeroporto non è pienamente operativo. Dunque durante le ore notturne il livello acustico si aggira intorno ai 30 dBA che è un valore di fondo tipico per una zona extraurbana. Queste zone periferiche sono quelle tipiche nelle quali sono situate le infrastrutture aeroportuali; osservando la serie storica delle misurazioni è facile notare che le valli del segnale sono in corrispondenza delle ore notturne.

Al fine di ottenere la stima del vettore dei parametri per il modello di Poisson non omogeneo, si è utilizzato lo strumento di ottimizzazione di Matlab per massimizzare la funzione di verosimiglianza. A causa dell'alto numero di parametri e della conseguente complessità della procedura di ottimizzazione quando il modello prevede un *change-point*, il metodo della massimizzazione della verosimiglianza può essere usato con successo solo per il modello più semplice che non prevede *change-points*.

Per entrambe le soglie considerate, l'intervallo di ricerca dei due parametri per la massimizzazione è  $[0.1, 2]$  per il parametro alfa e  $[0.1, 100]$  per sigma. L'algoritmo è stato inizializzato con alfa = 0.5 e sigma = 30. Quando la soglia scelta è stata di 55 dBA, la funzione di verosimiglianza è stata massimizzata dopo 13 iterazioni ottenendo  $\hat{\alpha} = 0.999$  e  $\hat{\sigma} = 1.574$ . Invece con la soglia fissata a 60 dBA, dopo dodici iterazioni dell'algoritmo di Matlab, i valori ottenuti sono stati  $\hat{\alpha} = 1.312$  e  $\hat{\sigma} = 7.554$ .

È importante notare che scegliendo la soglia pari a 55 dBA, il processo  $N$  può essere considerato un processo di Poisson omogeneo (alfa  $\approx 1$ ). Invece quando si considera una soglia pari a 60 dBA si riscontra un processo non omogeneo con funzione del rateo di accadimento crescente (alfa  $> 1$ ).

Al fine di stimare i parametri seguendo un punto di vista bayesiano, sono usati campionamenti dalle rispettive distribuzioni di probabilità a posteriori. Poiché le distribuzioni a posteriori coinvolte non hanno una forma facile da trattare, è stato usato un algoritmo catene di Markov - Monte Carlo. L'algoritmo utilizzato è quello di campionamento di Gibbs implementato internamente al programma OpenBugs (si veda [www.openbugs.net/w](http://www.openbugs.net/w) e [121]).

In un primo momento non è stata considerata la presenza di un *change-point* e sono state usate distribuzioni a priori uniformi per entrambe le soglie e per entrambi i parametri alfa e sigma. In particolare si è considerata una distribuzione  $U(0.1, 2)$  per alfa e una  $U(0.1, 100)$  per sigma. Quando si è scelta la soglia 55 dBA e sono state usate distribuzioni a priori più informative, per alfa si è usata una normale  $N(1.032, 157.468)$  e una distribuzione gamma per sigma  $\text{Gamma}(6.9054, 3.5358)$ . Invece con la soglia di 60 dBA le distribuzioni a priori informative sono state  $N(1.351, 57.13)$  per alfa e  $\text{Gamma}(8.9884, 1.0367)$  per sigma (le distribuzioni gamma sono del tipo  $\text{Gamma}(a, b)$  con media  $a/b$  e varianza  $a/b^2$ ). In tutti i casi descritti la stima dei parametri è stata effettuata su di un campione di 22500 dati ottenuto da cinque catene dopo aver eliminato le prime 5000 estrazioni, e considerando una estrazione ogni 10.

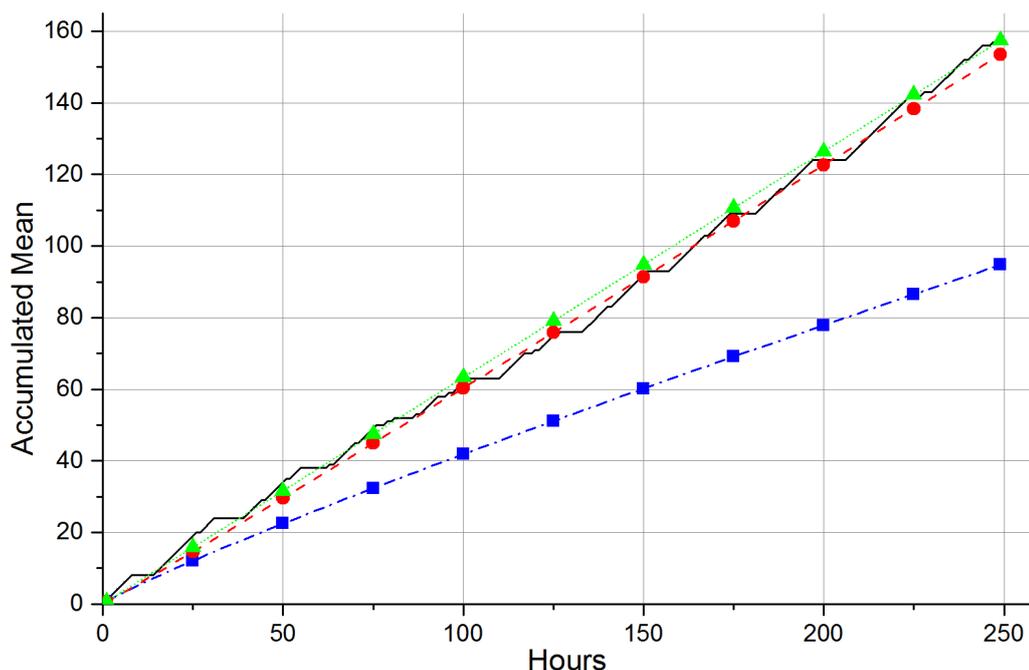
Nella tabella IV.1 è possibile notare che, con la soglia fissata a 55 dBA, considerando distribuzioni a priori uniformi e dunque non informative, la funzione del rateo di accadimento del modello di Poisson presenta un andamento decrescente (alfa  $< 1$ ). Tuttavia quando vengono introdotte distribuzioni a priori informative, il processo di Poisson tende ad essere omogeneo, ossia alfa è molto vicino all'unità. Quando viene considerata una soglia di 60 dBA, si osserva un rateo di accadimento crescente con il tempo, sia partendo da distribuzioni a priori informative che non informative: questo risultato, correttamente interpretato, offre l'informazione che al passare del tempo la soglia scelta viene superata più di frequente.

Al fine di verificare l'adeguatezza dei modelli proposti, si è usato un confronto grafico nelle figure IV.2 e IV.3 diagrammando i valori della media cumulata realmente osservata e di quella stimata, per entrambe le soglie considerate. Per la soglia 55 dBA si può osservare che, sia il metodo frequentista che quello bayesiano utilizzando distribuzioni a priori informative, forniscono una buona approssimazione della media cumulata osservata.

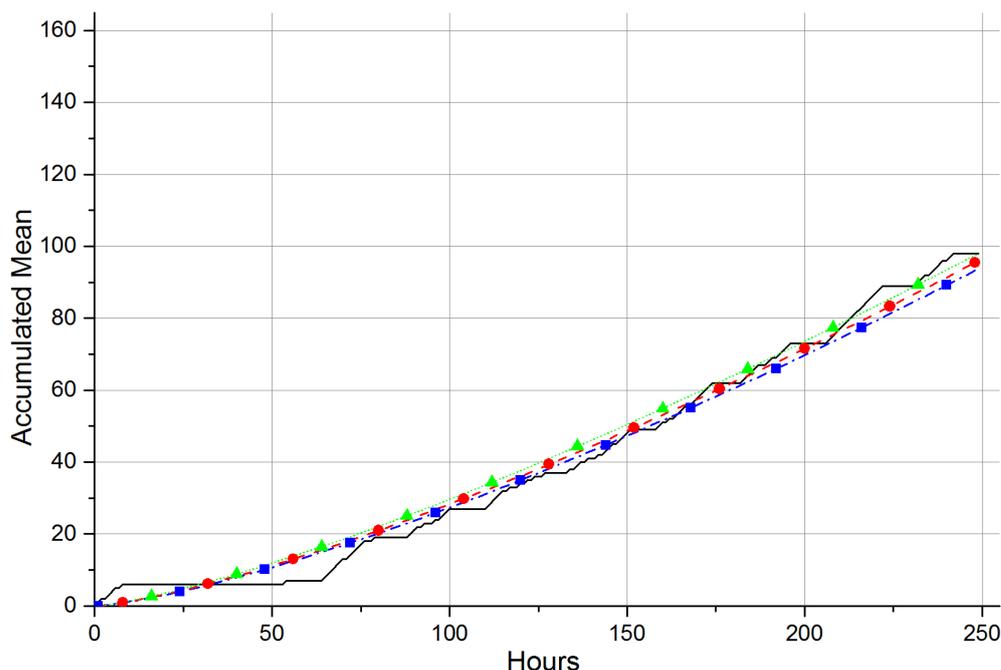
Tuttavia il metodo bayesiano non-informativo, produce un'approssimazione della curva osservata non soddisfacente dato che si osserva una notevole deriva tra le due curve. Quando invece si considera la soglia 60 dBA, le tre metodologie proposte forniscono una previsione affidabile delle medie cumulate realmente osservate, dunque le curve stimate approssimano fedelmente quella reale.

Guardando la figura IV.3 è possibile concludere che la modellazione mediante l'introduzione di un *change-point* potrebbe essere vantaggiosa. Partendo dalle informazioni ottenute dall'applicazione del modello senza *change-point*, le distribuzioni a priori scelte sono state:  $\text{Gamma}(64,80)$  per  $\alpha_1$ ,  $N(1.351,57.13)$  per  $\alpha_2$ ,  $\text{Gamma}(64,16)$  per  $\sigma_1$  e  $\text{Gamma}(8.9584,1.0367)$  per  $\sigma_2$ . Per il parametro relativo alla localizzazione temporale del *change-point*  $\tau$  la distribuzione a priori scelta è  $N(65,0.03)$ ; un campione di 22500 valori ottenuto da cinque catene dopo aver scartato le prime 5000 estrazioni e prendendo un valore ogni 10, è stato usato per stimare i parametri di interesse.

Guardando i valori di questi parametri in tabella IV.2 è possibile notare che nell'intervallo di tempo  $(0, \tau)$ , la funzione del rateo di accadimento ha un andamento decrescente col tempo ( $\alpha_1 < 1$ ). Invece dopo il periodo  $\tau$  si verifica un cambiamento nel rateo di accadimento: la funzione diventa crescente da questo punto in poi ( $\alpha_2 > 1$ ). In altre parole la modellazione e i suoi parametri forniscono l'informazione che dalla 62-esima ora in avanti (che è il valore approssimativo per la stima del *change-point*) i superamenti di soglia sono più frequenti: l'inquinamento acustico è aumentato.



**Fig. IV.2:** Media cumulata realmente osservata del modello di Poisson non omogeneo (linea continua nera) e medie cumulate stimate usando la massimizzazione della funzione di verosimiglianza (triangoli verdi), l'inferenza bayesiana non informativa (quadrati blu) e informativa (cerchi rossi) per le distribuzioni apriori senza l'utilizzo di *change-points*. Il grafico si riferisce alla scelta della soglia di 55 dBA.



**Fig. IV.3:** Media cumulata realmente osservata del modello di Poisson non omogeneo (linea continua nera) e medie cumulate stimate usando la massimizzazione della funzione di verosimiglianza (triangoli verdi), l'inferenza bayesiana non informativa (quadrati blu) e informativa (cerchi rossi) per le distribuzioni apriori senza l'utilizzo di *change-points*. Il grafico si riferisce alla scelta della soglia di 60 dBA.

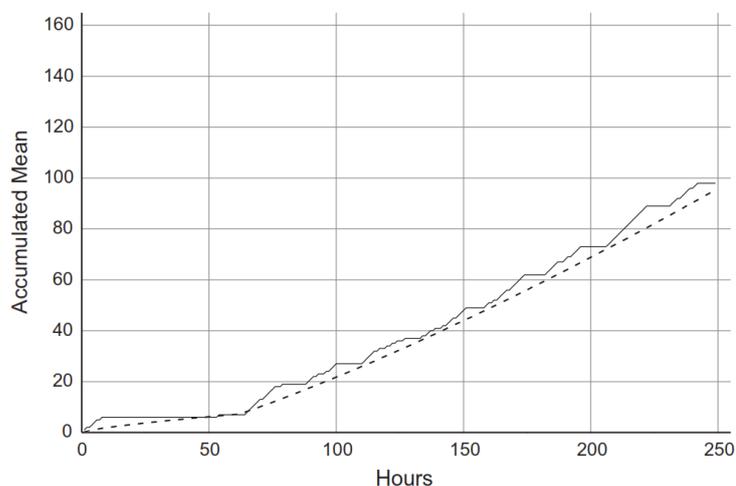
**Tab. IV.1:** Media a posteriori e deviazione standard per i parametri stimati  $\alpha$  e  $\sigma$  quando è usata per il rateo di accadimento la funzione di Weibull e per entrambe le soglie scelte. La notazione tra parentesi si riferisce all'uso o meno di distribuzioni a priori informative.

Parametro	Media	Media	Dev.Std.	Dev.Std.
	soglia 55 dBA	soglia 60 dBA	soglia 55 dBA	soglia 60 dBA
$\alpha$ (non-inform.)	0.897	1.350	0.277	0.131
$\alpha$ (informativa)	1.024	1.340	0.647	2.842
$\sigma$ (non-inform.)	1.555	8.640	1.032	0.077
$\sigma$ (informativa)	1.825	8.240	0.418	1.647

**Tab. IV.2:** Media a posteriori e deviazione standard per i parametri alfa, sigma e tau quando si considera un *chang-point* e la soglia scelta è 60 dBA.

Parametro	Media	Dev.Std.
	soglia 60 dBA	soglia 60 dBA
$\alpha_1$	0.722	0.073
$\alpha_2$	1.338	0.087
$\sigma_1$	4.020	0.448
$\sigma_2$	7.718	1.858
$\tau$	62.44	2.554

Nella figura IV.4 si può vedere come il modello con l'implementazione del *change-point* fornisce una approssimazione ottima della media cumulata realmente osservata. In particolare il confronto grafico tra i valori reali di superamento e quelli previsti mostrano che il modello capace di descrivere meglio l'andamento dei dati è quello non omogeneo di Poisson prevedendo l'introduzione del *change-point*.



**Fig. IV.4:** Medie cumulative realmente osservate (linea continua) e previste (linea tratteggiata) del processo di Poisson non omogeneo quando è considerata la presenza di un *change-point*.

Oltre al confronto grafico sono stati calcolati anche gli indici SAD e CV per ogni modellazione proposta. I valori di queste metriche dell'errore di previsione sono mostrati nella tabella IV.3 insieme alla media  $m$  e alla deviazione standard  $s$  usate per calcolare CV. Se il criterio usato per la scelta del modello è la minimizzazione del SAD, il modello da preferire è quello che sfrutta la tecnica bayesiana con distribuzioni a priori informative ma senza *change-point*. Usando invece la minimizzazione del CV la tecnica bayesiana con distribuzioni a priori informative è ancora quella da preferire se la soglia scelta è 55 dBA, ma con soglia di 60 dBA prevale nettamente il modello bayesiano che prevede l'introduzione del *change-point*.

Si consideri che piccoli valori del CV indicano che in media la differenza tra il valore reale e quello stimato è molto raccolta intorno alla media. Nell'analisi con soglia fissata a 60 dBA ottengono un basso valore di CV sia il modello bayesiano con distribuzioni a priori informative sia quello con la presenza del *change-point*, con un significativo vantaggio a favore di quest'ultimo. Tuttavia se si guardano i valori di  $m$  e  $s$  è possibile notare che questi sono simili ma con un leggero vantaggio a favore del modello senza *change-point*. Pertanto si può concludere che nessuno di questi indici può fornire una risposta definitiva sul modello da scegliere, ma solo la loro valutazione globale in concomitanza ad un confronto grafico può dare una vantaggiosa indicazione sul tipo di modellazione più appropriata per quel particolare set di dati analizzato. È da tenere in grande considerazione in questi casi anche la complessità del modello costruito, il numero di parametri previsto e il carico computazionale richiesto da una stima di questi ultimi. È importante notare anche che questo tipo di modellazione per eventi di superamento fornisce risultati molto variabili quando applicato agli stessi dati ma con una differente scelta della soglia di interesse.

**Tab. IV.3:** Per le due soglie scelte e per le varie tecniche usate durante la stima dei parametri sono mostrati i valori di SAD, CV, media e deviazione standard degli errori. In ordine sono presentati i risultati per il metodo della massimizzazione della verosimiglianza, metodo bayesiano con distribuzioni a priori non informative e informative, e metodo bayesiano in presenza di un *change-point* usato solo con la soglia di 60 dB.

Metrica/Soglia	MaxLike	BayesNonInfo	BayesInfo	BayesChPt
SAD (55 dBA)	670.07	6762.99	550.95	–
CV (55 dBA)	0.719	0.65	0.63	–
$m$ (55 dBA)	2.69	27.16	2.21	–
$s$ (55 dBA)	1.934	17.67	1.4	–
SAD (60 dBA)	835.87	768.89	739.35	797.36
CV (60 dBA)	0.604	0.67	0.599	0.565
$m$ (60 dBA)	3.36	3.09	2.97	3.2
$s$ (60 dBA)	2.03	2.07	1.78	1.81

#### 4.1.4 Discussione sui risultati ottenuti

In questo capitolo è stata usata una modellazione mediante distribuzioni di Poisson non omogenee per studiare l'andamento di un set di misurazioni del livello di rumorosità. Il fenomeno fisico che è stato indagato riguarda il numero di volte medio che una soglia prestabilita di rumorosità viene superata dalle misure di livello acustico. Il modello proposto è stato applicato ai livelli di rumorosità rilevati presso la zona aeroportuale di Nizza - Costa Azzurra situata nel sud della Francia. Sono state prese in considerazione due diverse soglie:  $L = 55$  dBA e  $L = 60$  dBA; con quest'ultimo valore della soglia si è rilevata la presenza di un *change-point* e questa tecnica è stata implementata nel modello per migliorarne le capacità previsionali. Il confronto grafico tra la media cumulata dei superamenti realmente osservata e quella prevista dal modello mostra che nel caso di  $L = 55$  dBA la migliore approssimazione della realtà si ottiene con la tecnica bayesiana con distribuzioni apriori dei parametri informative. Nel caso di  $L = 60$  la modellazione migliore si ottiene con l'utilizzo di un *change-point* e usando distribuzioni a priori informative. I risultati raggiunti mostrano che con soglia di 55 dBA il processo  $N$  è approssimativamente del tipo Poisson omogeneo con rateo di accadimento pari a  $\lambda(t) = \lambda \approx (1/\sigma) = (1/1.825) \approx 0.55$ . In questo caso, se l'interesse è calcolare la probabilità che durante un intervallo di tempo  $[t, t+s)$ ,  $t, s, \geq 0$ , ci siano  $k$  ( $k = 0, 1, \dots$ ) ore nelle quali il livello di rumorosità superi i 55 dBA, può essere usata la seguente formula semplificata della equazione IV.2:

$$P(N_s = k) = \frac{(\lambda s)^k}{k!} \exp(-(\lambda s)), \quad s \geq 0. \quad (\text{IV.8})$$

Se ad esempio si vuole stimare la probabilità di avere 4 superamenti della soglia 55 dBA in un intervallo di tempo di 10 ore, basta sostituire nella formula precedente i parametri stimati e si ottiene:

$$P(N_{10} = 4) = \frac{(0.55 * 10)^4}{4!} \exp(-(0.55 * 10)) \approx 0.16. \quad (\text{IV.9})$$

Quando invece la soglia considerata è 60 dBA, e il modello con *change-point* è usato, i dati sono ben descritti da un processo non omogeneo con un rateo di accadimento crescente con il tempo a partire dalla 62-esima ora. Volendo conoscere la probabilità di osservare 10 superamenti della soglia nei successivi 24 periodi seguenti l'intervallo di osservazione è possibile utilizzare la formula IV.2 con gli appropriati valori di  $s$  e  $t$  e i valori stimati dei parametri alfa e sigma. In questo caso descritto  $t = 249$ , dalla tabella IV.3 vediamo che  $\hat{\alpha} = 1.338$  e  $\hat{\sigma} = 7.718$ , dunque  $1/\hat{\sigma} \approx 0.13$ . Sostituendo questi valori nell'equazione IV.2 si ottiene:

$$P(N_{249+s} - N_{249} = k) = \frac{[(0.13*(249+s))^{1.338} - (0.13*249)^{1.338}]^k}{k! * \exp(-[(0.13 * (249 + s))^{1.338} - (0.13 * 249)^{1.338}])}, \quad (IV.10)$$

Ponendo dunque  $s = 24$  e  $k = 10$  la probabilità cercata sarà  $P(N_{273} - N_{249} = 10) \approx 0.071$ . altro esempio può essere valutato ponendo  $k = 4$ , allora la relativa probabilità sarà  $P(N_{273} - N_{249} = 4) \approx 0.0016$ . Si supponga in seguito di essere interessati a conoscere la probabilità che 4 superamenti della soglia 60 dBA si verifichino nelle 10 ore immediatamente successive al periodo di osservazione: è sufficiente sostituire nella formula IV.10  $s = 10$  e  $k = 4$  per ottenere la probabilità cercata  $P(N_{259} - N_{249} = 4) \approx 0.148$ . In maniera analoga è possibile calcolare la probabilità desiderata per altri valori assegnati di  $s$  e  $k$ .

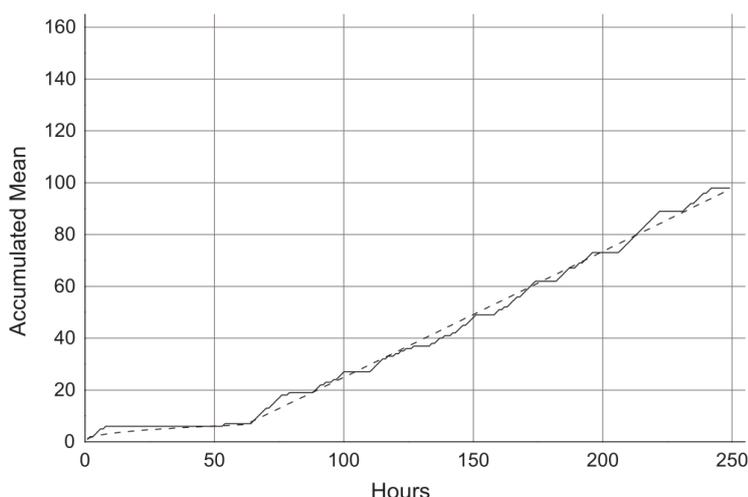
È interessante notare che il *change-point* stimato  $\tau \approx 62$  corrisponde al periodo intorno alle 17:48 del 24 dicembre 2000: per il fatto che il traffico aereo è in crescita per il giorno di natale, il livello medio di rumorosità nella zona tende ad essere più alto in questo periodo. Questo fenomeno si traduce in un aumento del numero di superamenti per unità di tempo della soglia stabilita. Dunque anche da questo punto di vista dell'interpretazione della serie storica il modello con *change-point* riflette bene l'andamento dei dati. Naturalmente le versioni semplificate della modellazione non riescono a cogliere questa caratterizzazione della serie.

È stato completato anche un ulteriore tentativo di portare un miglioramento nella tecnica di modellazione utilizzando una metodologia ibrida: dopo aver stimato il valore del periodo di *change-point* con la tecnica bayesiana descritta, la massimizzazione della verosimiglianza è stata applicata per stimare separatamente i parametri per ciascun sotto intervallo dei dati ottenuto. Infatti si è potuta suddividere la serie in un intervallo temporale prima del *change-point* e in uno successivo a questo. Con i nuovi parametri stimati con questa metodologia, si è ottenuta un'ottima approssimazione della curva reale osservata; in particolare i valori ottenuti per i parametri sono stati  $\hat{\alpha}_1 = 0.40$ ,  $\hat{\alpha}_2 = 1.02$ ,  $\hat{\sigma}_1 = 0.50$  e  $\hat{\sigma}_2 = 2.21$ ; si è ottenuto, con questa configurazione, un valore del SAD = 398.68 del CV = 0.74 e infine una media  $m = 1.6$  e una deviazione standard  $s = 1.8$ .

Usando le informazioni estratte dall'applicazione della massimizzazione della verosimiglianza appena descritta, si è potuto assegnare ai parametri coinvolti una distribuzione apriori particolarmente informativa e in questo modo ritentare un approccio completamente bayesiano mediante il programma OpenBugs. In particolare per  $\tau$  si è usata una distribuzione a priori identica alle elaborazioni precedenti, mentre per gli altri parametri si è assegnata: *Gamma*(16,40) per  $\hat{\alpha}_1$ , *Gamma*(26,25) per  $\hat{\alpha}_2$ , *Gamma*(25,50) per  $\hat{\sigma}_1$  e *Gamma*(122,55) per  $\hat{\sigma}_2$ . Per  $\tau$  si è ottenuto di nuovo un valore di circa 62, mentre per gli altri valori dei parametri:  $\hat{\alpha}_1 = 0.39$ ,  $\hat{\alpha}_2 = 1.02$ ,  $\hat{\sigma}_1 = 0.50$  e  $\hat{\sigma}_2 = 2.23$ . Con queste stime i valori delle metriche d'errore sono stati: SAD = 411.16 del CV = 0.78 con una media  $m = 1.65$  e una deviazione standard  $s = 1.29$ .

Confrontando questi risultati con quelli della tabella IV.3 è possibile concludere che la stima ibrida dei parametri presentata in precedenza, quando il modello contempla la presenza del *change-point*, è quella che fornisce i risultati più bassi, e dunque le prestazioni migliori, di SAD e CV. In questo caso è comunque stato rilevato un processo di Poisson non omogeneo con un rateo di accadimento decrescente nel tempo per la prima parte dei dati, ossia quella precedente al *change-point*; mentre per la seconda parte della serie, successiva al *change-point*, si è riscontrato un processo omogeneo. Nella figura IV.5 è mostrato il confronto grafico tra le medie cumulate realmente osservate e quelle previste dal modello stimato con la metodologia ibrida descritta.

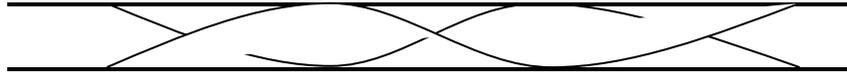
Si tenga in considerazione che le varie tecniche di modellazione qui sviluppate e descritte (con e senza *change-points*), possono essere applicate a qualsiasi serie storica di rumorosità aeroportuale opportunamente misurata.



**Fig. IV.5:** Medie cumulative realmente osservate (linea continua) e previste (linea tratteggiata) del processo di Poisson non omogeneo con un *change-point*: sono state usate, per la stima dei parametri, distribuzioni a priori molto informative grazie alla modellazione ibrida descritta.

Tali metodologie possono essere applicate anche ai casi nei quali è preso in considerazione esclusivamente il contributo al campo acustico degli aerei, ad esempio mediante un sistema di monitoraggio della rumorosità degli aeromobili come quello descritto nelle documentazioni standard, si veda ad esempio [122,123]. Tali modelli in assenza di *change-point* sono stati usati anche in [5] al fine di rispondere alle domande qui affrontate. In quei casi il set di misurazioni conteneva livelli di rumorosità in un contesto ambientale nel quale non era presente una sorgente predominante ben identificabile. altre applicazioni con e senza *change-point* sono state applicate per studiare problemi di inquinamento dell'aria [98,110].

Dunque le metodologie proposte sono molto flessibili e possono essere applicate in vari contesti; sono infatti utilizzabili ovunque ci sia l'interesse a stimare la probabilità che i valori di una serie di misurazioni superino una soglia scelta un certo numero di volte in un intervallo di tempo stabilito. Queste misurazioni possono essere, oltre a dati di livello acustico o di altri inquinanti, livelli di assorbimento energetico, valori di titoli azionari, numeri di avaria in una macchina o livelli di scorte in un magazzino.



## **Conclusioni**



Il presente elaborato ha affrontato lo studio della modellazione di successioni di dati acquisiti ad intervalli di tempo equidistanti, successioni classificate in letteratura come serie storiche. In particolare i modelli proposti sono adatti alla descrizione e previsione di serie storiche “univariate”: l’informazione è estratta da una successione di variabili della stessa tipologia studiandone l’evoluzione temporale. La corretta e approfondita analisi delle serie storiche univariate è utile in differenti ambiti dell’ingegneria, della fisica applicata, dell’economia e della finanza.

Ad esempio per trattare lo spinoso problema della concentrazione di agenti nocivi nelle aree fortemente urbanizzate la disponibilità di numerose misurazioni del livello di inquinanti nelle zone di interesse è fondamentale ed è alla base dei tentativi volti a sviluppare modelli previsionali per l’andamento di questi stessi inquinanti. Riuscire a sviluppare previsioni efficaci è vantaggioso sia per evitare che la concentrazione degli agenti nocivi superi determinate soglie anche solo per brevi periodi, sia per ridurre l’impatto economico delle misure volte a ridurre l’emissione delle fonti di inquinamento, come ad esempio blocchi o limitazioni del traffico. Inoltre una consapevole interpretazione di alcuni possibili tecniche di modellazione consente, anche a posteriori, di valutare numericamente gli effetti degli interventi di mitigazione degli inquinanti posti in atto.

Le tecniche implementate nel presente lavoro di tesi possono essere classificate in due distinte tipologie, differenti ma complementari: una basata sull’analisi delle serie storiche delle misure di interesse, l’altra su distribuzioni di Poisson per gli eventi di superamento di una soglia stabilita. Il primo metodo effettua inferenza sul campione di dati misurati: tale modello di analisi delle serie storiche è particolarmente efficace se le misurazioni sono affette da una stagionalità manifesta. I set di misurazioni di uno dei casi analizzati presentano una stagionalità settimanale marcata: la validità di siffatti modelli è stata testata su dati di rumore raccolti nella città di Messina (si è analizzato il livello continuo equivalente di pressione sonora utilizzando poi una ponderazione con curva *A*). Le misurazioni si riferiscono a livelli acustici diurni e notturni, rilevati presso una stazione di monitoraggio, in viale Bocchetta, predisposta dall’amministrazione locale e resi pubblici su apposita piattaforma web. Le misure sono molto raccolte intorno ai valori statistici centrali (media e mediana) anche a causa dell’utilizzo di un livello equivalente giornaliero ( $L_{eq16h}$  e  $L_{eq8h}$ ) che comporta diminuzione della varianza.

Nel primo capitolo sono state sviluppate tecniche deterministiche basate sulla decomposizione nelle componenti di trend e stagionali di una sequenza di dati osservata. Si è in seguito ottenuto un potenziamento della modellazione per migliorare la previsione e l’analisi: in particolare si è analizzato un set di dati di assorbimento di energia elettrica dovuto al sistema di trasporto pubblico della città di Sofia, migliorando l’estrazione di informazioni dalla serie e le prestazioni grazie all’introduzione di un ulteriore coefficiente di stagionalità.

Nel secondo capitolo inizialmente si è studiata una serie di misurazioni fonometriche acquisite in prossimità dell’aeroporto internazionale di Nizza (Francia); a tal fine sono stati adottati modelli stocastici stagionali auto-regressivi a media mobile (SARIMA) confrontati con le tecniche deterministiche presentate in precedenza. Nei livelli acustici in prossimità della struttura aeroportuale si riscontra una stagionalità giornaliera (periodicità nei dati di 24 ore) e un trend crescente per i livelli emessi dovuto all’avvicinarsi del periodo natalizio con conseguente aumento di traffico aereo e rumore antropico.

Successivamente ci si è concentrati sull'implementazione di questi modelli previsionali per lo studio della velocità del vento in un sito dove è installato un impianto per la produzione elettrica mediante aerogeneratori. In seguito si sono applicati modelli per la previsione dell'inquinamento acustico prodotto dal parco eolico investito da vento ad una certa velocità.

Nel terzo capitolo si è migliorata l'integrazione di tecniche previsionali lineari e non lineari mediante reti neurali artificiali; in particolare lo stato dell'arte per la modellazione e la previsione di serie storiche si è raggiunto con una tecnica ibrida costruito sull'utilizzo in cascata di metodi deterministici, basati sulla scomposizione della serie in componenti di trend e stagionalità, seguiti da modellazione tramite reti neurali artificiali per una migliore previsione della parte non lineare della serie.

Nel quarto ed ultimo capitolo è stato implementato un modello di previsione per eventi di superamento di soglie di inquinamento acustico. Tale modello è basato sull'assunzione che gli eventi di superamento sono distribuiti secondo una distribuzione di Poisson non omogenea. Il modello proposto effettua inferenza statistica dal campione di istanti temporali per i quali si è avuto un evento di superamento della soglia prefissata durante i periodi di misurazione. Si è dunque supposta una distribuzione di Poisson non omogenea per la probabilità di avere un certo numero di superamenti in un intervallo temporale; a caratterizzare il processo poissoniano è una *rate function* di tipo Weibull non esponenziata. Questo approccio può essere a sua volta perseguito con tecniche frequentiste o bayesiane per la stima dei parametri della "*Probability Density Function*" (PDF). In particolare è stato studiato la stessa serie di misurazioni fonometriche acquisite in prossimità dell'aeroporto internazionale di Nizza (Francia) usata anche nel secondo capitolo. Il modello previsionale realizzato prevede l'introduzione della metodologia "*change-point*" singolo per la stima dei parametri della distribuzione. Tali parametri sono stati stimati grazie al campionamento Monte-Carlo Markov-Chain basato su assunzioni di statistica bayesiana.

Tale modello riesce a fornire previsioni per il superamento della soglia in maniera rapida ed efficace in tutti i casi trattati, inoltre essendo un modello a due parametri è trattabile facilmente con un approccio bayesiano empirico: è possibile cominciare la ricerca dei parametri con distribuzioni a priori non informative e poi, analizzando i risultati, si può iterare il procedimento con distribuzioni più informative. Nei casi trattati la convergenza degli algoritmi MCMC del programma OpenBugs si è raggiunta in un numero limitato di iterazioni.

# Elenco completo pubblicazioni del candidato

## Publicazioni su riviste internazionali:

- I. C. Guarnaccia, J. Quartieri, C. **Tepedino**, *Integration of ARIMA and Software Models for Wind Speed Forecast and Noise Map Prediction in a Wind Farm*, International Journal of Mathematical Models and Methods in Applied Sciences, Vol. 10, pp 259-269 (2016), ISSN: 1998-0140.
- II. Guarnaccia C., Quartieri J., **Tepedino C.**, *Wind Farm Noise Maps in a Country Side Area*, in “International Journal of Applied Physics”, Vol.1, pp. 69-76, 2016.
- III. C. Guarnaccia, J. Quartieri, C. **Tepedino**, E. R. Rodrigues, *A time series analysis and a non-homogeneous Poisson model with multiple change-points applied to acoustic data*, Applied Acoustics 114 (2016) 203–212.
- IV. C. Guarnaccia, J. Quartieri, N. E. Mastorakis, C. **Tepedino**, *Environmental Noise Level Threshold Surpassing Analysis by Non-Homogeneous Poisson Model with Informative and Non-Informative Prior Distributions*, International Journal of Mechanics, Vol. 10, pp. 14-22 (2016), ISSN: 1998-4448.
- V. C. Guarnaccia, J. Quartieri, C. **Tepedino**, L. Petrovic, *A Comparison of Imputation Techniques in Acoustic Level Datasets*, International Journal of Mechanics, Vol. 9, pp. 272-278 (2015), ISSN: 1998-4448.
- VI. C. Guarnaccia, J. Quartieri, C. **Tepedino**, S. Iliev, S. Popova, *Neural Network and Time Series Analysis Approaches in Predicting Electricity Consumption of Public Transportation Vehicles*, WSEAS Transactions on Environment and Development, Vol. 11, pp. 312-324 (2015), E-ISSN: 2224-3496.
- VII. C. **Tepedino**, C. Guarnaccia, S. Iliev, S. Popova, J. Quartieri, *A Forecasting Model Based on Time Series Analysis Applied to Electrical Energy Consumption*, International Journal of Mathematical Models and Methods in Applied Sciences, Vol. 9, pp 432-445 (2015), ISSN: 1998-0140.
- VIII. C. Guarnaccia, J. Quartieri, C. **Tepedino**, E. R. Rodrigues, *An analysis of airport noise data using a non-homogeneous Poisson model with a change-point*, Applied Acoustics, Vol. 91, pp. 33-39, 2015, doi:10.1016/j.apacoust.2014.12.002.

- IX. C. Guarnaccia, J. Quartieri, E. R. Rodrigues, **C. Tepedino**, *Acoustical Noise Analysis and Prediction by means of Multiple Seasonality Time Series Model*, International Journal of Mathematical Models and Methods in Applied Sciences, Vol. 8, pp 384-393 (2014), ISSN: 1998-0140.
- X. C. Guarnaccia, J. G. Cerón Bretón, J. Quartieri, **C. Tepedino**, R. M. Cerón Bretón, *An Application of Time Series Analysis for Forecasting and Control of Carbon Monoxide Concentrations*, International Journal of Mathematical Models and Methods in Applied Sciences, Vol. 8, pp 505-515 (2014), ISSN: 1998-0140.
- XI. C. Guarnaccia, J. Quartieri, N. E. Mastorakis, **C. Tepedino**, *Development and Application of a Time Series Predictive Model to Acoustical Noise Levels*, WSEAS Transactions on Systems, Vol. 13, pp. 745-756 (2014), ISSN / E-ISSN: 1109-2777 / 2224-2678.

#### **Publicazioni in proceedings di conferenze internazionali con referee:**

- XII. Guarnaccia C., Quartieri J., **Tepedino C.**, *Seasonal ARIMA and Deterministic Time Series Models Applied to Airport Noise Forecasting*, Int. Conf. on Applied Mathematics and Computer Science, Rome, Italy, January 27-29, 2017, accepted and in press.
- XIII. Guarnaccia C., Quartieri J., **Tepedino C.**, *A Hybrid Predictive Model for Acoustic Noise in Urban Areas Based on Time Series Analysis and Artificial Neural Network*, Int. Conf. on Applied Mathematics and Computer Science, Rome, Italy, January 27-29, 2017, accepted and in press. .
- XIV. C. Guarnaccia, J. Quartieri, N. E. Mastorakis and **C. Tepedino**, *Analysis of Noise Level Exceedances by Exponential Rate Function in Non-Homogeneous Poisson Model*, in “Recent Advances in Environmental and Earth Sciences and Economics”, Proc. of the Int. Conf. on Energy, Environment, Development, Economics (EEDE '15), Zakynthos Island, Greece, 16-20 July 2015, pp. 335-339.
- XV. C. Guarnaccia, J. Quartieri, **C. Tepedino**, S. Iliev, S. Popova, *Public Transportation Energy Consumption Prediction by means of Neural Network and Time Series Analysis Approaches*, in “Recent Researches in Mechanical and Transportation Systems”, Proc. of the 6<sup>th</sup> Int. Conf. on Automotive and Transportation Systems (ICAT '15), Salerno, Italy, 27-29 June 2015, pp. 64-70.
- XVI. C. Guarnaccia, J. Quartieri, **C. Tepedino**, L. Petrovic, *Missing Data Reconstruction in Acoustic Level Long Term Monitoring*, in “Recent Researches in Electrical and Computer Engineering”, Proc. of the 3<sup>th</sup> Int. Conf. on Acoustics, Speech and Audio Processing (ASAP '15), Salerno, Italy, 27-29 June 2015, pp. 135-141.

- XVII. **Tepedino C.**, Guarnaccia C., Iliev S., Popova S., Quartieri J., *Time Series Analysis and Forecast of the Electricity Consumption of Local Transportation*, in “Recent Advances in Energy, Environment and Financial Planning”, Proc. of the 5<sup>th</sup> Int. Conf. on Development, Energy, Environment, Economics (DEEE '14), Firenze, Italy, 22-24 November 2014, pp. 13-22.
- XVIII. Guarnaccia C., Quartieri J., Cerón Bretón J. G., **Tepedino C.**, Cerón Bretón R. M., *Time Series Predictive Model Application to Air Pollution Assessment*, in “Latest Trends on Systems”, Proc. of the 18th Int. Conf. on Circuits, Systems, Communications and Computers (CSCC'14), Santorini, Greece, 17-21 July 2014, pp. 499-505.
- XIX. Guarnaccia C., Quartieri J., Mastorakis N. E. and **Tepedino C.**, *Acoustic Noise Levels Predictive Model Based on Time Series Analysis*, in “Latest Trends in Circuits, Systems, Signal Processing and Automatic Control”, proceedings of the 2nd Int. Conf. on Acoustics, Speech and Audio Processing (ASAP '14), Salerno, Italy, June 3-5, 2014, ISSN: 1790-5117, ISBN: 978-960-474-374-2, pp. 140-147.
- XX. Guarnaccia C., Quartieri J., Rodrigues E. R. and Tepedino C., *Time Series Model Application to Multiple Seasonality Acoustical Noise Levels Data Set*, in “Latest Trends in Circuits, Systems, Signal Processing and Automatic Control”, proceedings of the 2nd Int. Conf. on Acoustics, Speech and Audio Processing (ASAP '14), Salerno, Italy, June 3-5, 2014, ISSN: 1790-5117, ISBN: 978-960-474-374-2, pp. 171-180.

## Referenze

- [1] *Demographia World Urban Areas*, 9<sup>th</sup> Annual Edition, 2013.
- [2] Guarnaccia C., Mastorakis N. E., Quartieri J., Noise Sources Analysis in a Wood Manufacturing Company, *International Journal of Mechanics*, Issue 2, Vol. 7, pp 37-44 (2013), ISSN: 1998-4448.
- [3] Quartieri J., Mastorakis N. E., Iannone G., Guarnaccia C., D'Ambrosio S., Troisi A., Lenza T.L.L., *A Review of Traffic Noise Predictive Models*, Proceedings of the 5<sup>th</sup> WSEAS International Conference on "Applied and Theoretical Mechanics" (MECHANICS'09), Puerto de la Cruz, Tenerife, Spain, 14-16 December 2009, pp. 72-80.
- [4] Guarnaccia C., Lenza T.L.L., Mastorakis N.E., Quartieri J., A Comparison between Traffic Noise Experimental Data and Predictive Models Results, *International Journal of Mechanics*, Issue 4, Vol. 5, pp. 379-386 (2011), ISSN: 1998-4448.
- [5] Guarnaccia C., Advanced Tools for Traffic Noise Modelling and Prediction, *WSEAS Transactions on Systems*, Issue 2, Vol.12, 2013, pp. 121-130.
- [6] Iannone G., Guarnaccia C., Quartieri J., Speed Distribution Influence in Road Traffic Noise Prediction, *Environmental Engineering and Management Journal*, Vol. 12, Issue 3, 2013, pp. 493-501.
- [7] Guarnaccia C., Analysis of Traffic Noise in a Road Intersection Configuration, *WSEAS Transactions on Systems*, Issue 8, Volume 9, (2010), pp.865-874, ISSN: 1109-2777.
- [8] Quartieri J., Mastorakis N. E., Guarnaccia C., Troisi A., D'Ambrosio S., Iannone G., Traffic Noise Impact in Road Intersections, *International Journal of Energy and Environment*, Issue 1, Volume 4 (2010), pp. 1-8.
- [9] Box, G. E. P., and Jenkins, G., *Time Series Analysis: Forecasting and Control*, Holden-Day, 1976.
- [10] Chatfield, C., *The Analysis of Time Series: An Introduction*, Chapman & Hall, New York, 1975.
- [11] Di Matteo T., Aste T., Dacorogna M.M., Scaling behaviors in differently developed markets, *Physica A: Statistical Mechanics and its Applications*, Vol. 324, Issues 1–2, 2003, pp. 183-188.
- [12] Milanato D., *Demand Planning. Processi, metodologie e modelli matematici per la gestione della domanda commerciale*, Springer, Milano, 2008, in Italian.
- [13] Chase R. B., Aquilano N. J., *Operations Management for Competitive Advantage*, Irwin Professional Pub, 10<sup>th</sup> edition, 2004.
- [14] Montgomery D. C., Johnson L. A., Gardiner J. S., *Forecasting and Time Series Analysis*, McGraw-Hill, 1990.
- [15] <http://mobilitamessina.it/index.php/monitoraggio-ambientale> (giugno 2013).
- [16] *Directive 2002/49/EC of the European Parliament and of Council of June 25 2002 relating to the assessment and management of environmental noise*, Official Journal of the European Communities, L189/12-25, 18.7.2002
- [17] D.M. 16.03.1998, *Tecniche di rilevamento e di misurazione dell'inquinamento acustico*, Italian Ministry decree, 1998.
- [18] Kryter KD, *The Effects of Noise on Man*, 2nd edition, Orlando, FL, Academic Press, 1985.
- [19] Ouis D., "Annoyance from road traffic noise: a review", *Journal of Environmental Psychology*, Vol. 21, pp. 101-120, 2001.

- [20] Rodrigues, E.R., Achcar, J.A., Jara-Ettinger, J., "A Gibbs sampling algorithm to estimate the occurrence of ozone exceedances in Mexico City", in: *Air Quality: Models and Applications*, Popovic D (ed.), in Tech Open Access Publishers, pp. 131-150, (2011).
- [21] Achcar, J.A., Fernandez-Bremauntz, A.A., Rodrigues, E.R., Tzintzun, G., "Estimating the number of ozone peaks in Mexico City using a non-homogeneous Poisson model", *Environmetrics*, Vol. 19, pp 469-485, (2008).
- [22] Brockwell P., Davis R., *Introduction to Time Series and Forecasting* (2nd ed.), Springer, (2002).
- [23] Hamilton J.D., *Time Series Analysis*, Princeton University Press, Cloth, 1994.
- [24] Directive 2002/49/EC of the European Parliament and of Council of June 25 2002 relating to the assessment and management of environmental noise, Official Journal of the European Communities, L189/12-25, 18.7.2002.
- [25] Box, G. E. P., Pierce, D. A., "Distribution of Residual Autocorrelations in Autoregressive-Integrated Moving Average Time Series Models", *Journal of the American Statistical Association*, 65: 1509–1526, (1970).
- [26] Ljung G. M., Box, G. E. P., "On a measure of lack of fit in time series models", *Biometrika*, 65, 297-303, (1978).
- [27] Chambers, John, William Cleveland, Beat Kleiner and Paul Tukey, *Graphical Methods for Data Analysis*, Wadsworth, 1983.
- [28] Shapiro S.S., Wilk M.B., "An Analysis of Variance Test for Normality", *Biometrika* Vol. 52, N. 3/4, pp. 591-611 (1965)
- [29] Jarque C. M., Bera A. K., "A test for normality of observations and regression residuals", *International Statistical Review* 55, 163–172 (1987).
- [30] De Filippo S., Tepedino C., "Un possibile bilancio della scelta di investire su eolico e fotovoltaico in Italia", <http://www.ftnews.it/articolo.asp?cod=825>, febbraio 2017.
- [31] Deng S. J., Oren S. and Gross G., "Design and Valuation of Demand Response Mechanisms and Instruments for Integrating Renewable Generation Resources in a Smart Grid Environment", in *PSERC Report 12-24*, September 2012.
- [32] Mancarella P., Chicco G., "Real-time demand response from energy shifting in Distributed Multi-Generation", *IEEE Transactions on Smart Grid*, 4 (2013) 1928-1938.
- [33] <http://energy.gov/oe/technology-development/smart-grid/demand-response> (November 2014)
- [34] Iliev S., Popova S., "Electricity Consumption Prediction System for the Public Transportation", *WSEAS Transactions on Systems*, 13 (2014) 638-643.
- [35] Popova S., Iliev S., Trifonov M., "Neural Network Prediction of the Electricity Consumption of Trolleybus and Tram Transport in Sofia City", in *Latest Trends in Energy, Environment and Development, Proc. of the Int. Conf. on Urban Planning and Transportation (UPT'14)*, Salerno (Italy), June 2014, pp. 116-120.
- [36] Morano, P., Tajani, F., "Bare ownership evaluation. Hedonic price model vs. artificial neural network", *International Journal of Business Intelligence and Data Mining*, Vol. 8, No. 4, (2013), pp. 340-362.
- [37] Chen B.J., Chang M.W., Lin C.J., "Load Forecasting using Support Vector Machines: A Study on EUNITE Competition 2001", *Technical report, Department of Computer Science and Information Engineering*, National Taiwan University, 2002.
- [38] Charytoniuk W., Chen M.S., Van Olinda P., "Nonparametric Regression Based Short-Term Load Forecasting", *IEEE Transactions on Power Systems*, 13 (1998) 725–730.
- [39] Morano, P., Tajani, F., "Least median of squares regression and minimum volume ellipsoid estimator for outliers detection in housing appraisal", *International Journal of Business Intelligence and Data Mining*, Vol. 9, No. 2, (2014), pp. 91-111.
- [40] Cho M.Y., Hwang J.C., and Chen C.S., "Customer Short-Term Load Forecasting by using ARIMA Transfer Function Model", *Proc. of the Int. Conf. on Energy Management and Power Delivery*, 1995, 1 pp. 317–322.
- [41] Feinberg E.A., Hajagos J.T., and Genethliou D., "Statistical Load Modeling", *Proc. of the 7th IASTED Int. Multi-Conf.: Power and Energy Systems*, Palm Springs, CA, 2003, pp. 88–91.

- [42] Kiartzis S.J. and Bakirtzis A.G., “A Fuzzy Expert System for Peak Load Forecasting: Application to the Greek Power System”, *Proc. of the 10th Mediterranean Electrotechnical Conf.*, 2000, 3 pp. 1097–1100.
- [43] Iannone G., Troisi A., Guarnaccia C., D'Agostino P. P., Quartieri J., “An Urban Growth Model Based on a Cellular Automata Phenomenological Framework”, *Int. Journal of Modern Physics C*, Volume 22, Issue 05, pp. 543-561. DOI: 10.1142/S0129183111016427, (2011).
- [44] Pope C.A., Dockery D.W., Spengler J.D., and Raizenne M.E., “Respiratory Health and PM10 Pollution: A Daily Time Series Analysis”, *American Review of Respiratory Disease*, Vol. 144, No. 3\_pt\_1, (1991) pp. 668-674.
- [45] Dominici F., McDermott A., Zeger S.L., and Samet J.M., “On the Use of Generalized Additive Models in Time-Series Studies of Air Pollution and Health”, *American Journal of Epidemiology*, 156 (3), (2002) pp 193-203.
- [46] Lee T.H., White H., and Granger C.W.J., “Testing for neglected nonlinearity in time series models”, *Journal of Econometrics* 56, (1993) 269-290.
- [47] Teraesvirta T., Lin C.F., and Granger C.W.J., “Power of the Neural Network Linearity Test”, *Journal of Time Series Analysis*, 14 (1993) 209-220.
- [48] Said S.E. and Dickey D.A., “Testing for Unit Roots in Autoregressive-Moving Average Models of Unknown Order”. *Biometrika*, 71 (1984) 599-607.
- [49] Phillips P.C.B., Perron P., “Testing for a Unit Root in Time Series Regression”, *Biometrika* 75 (2), (1988) 335–346. doi:10.1093/biomet/75.2.335
- [50] <http://www.elektrotransportsf.com/index.php?lang=en> (November 2014)
- [51] Air Passenger Market Analysis - December 2015, International Air Transport Association (IATA), 2016.
- [52] W. Schlenker and W. Reed Walker, Airports, Air Pollution, and Contemporaneous Health, National Bureau of Economic Research (NBER), Working Paper No. 17684, December 2011.
- [53] M. Genescà, J. Romeu, R. Arcos, S. Martin, *Transportation Research Part D*, 18, pages 70–77, (2013).
- [54] M. Genescà, U. P. Svensson, G. Taraldsen, *J. Acoust. Soc. Am.* 137, pages 1914-1922, (2015); doi: 10.1121/1.4916196.
- [55] B. Podobnik and H. E. Stanley, *Phys.Rev.Lett.* 100, 084102, (2008).
- [56] G. Widman, T. Schreiber, B. Rehberg, A. Hoeft, and C. E. Elger, *Phys. Rev. E* 62, 4898, (2000).
- [57] D. Vere-Jones, *International Journal of Forecasting* 11(4), pp. 503–538 (1995).
- [58] P.D. Cryer, K. Chan, *Time Series Analysis, with applications in R*, (Second Edition, Springer, 2008).
- [59] P.H. Franses, *International Journal of Forecasting* 32, pp. 20–22 (2016).
- [60] R.J. Hyndman, G. Athanasopoulos, *Forecasting: principles and practice*, (OTexts, 2013).
- [61] W. D. Colby, R. Dobie, G. Leventhall, D. M. Lipscomb, R. J. McCunney, M. T. Seilo, B. Søndergaard, *Wind Turbine Sound and Health Effects: An Expert Panel Review*, prepared for American Wind Energy Association and Canadian Wind Energy Association, December 2009.
- [62] GWEC, *Global Wind Statistics*, 2016.
- [63] B. Berlund, T. Lindvall, D.H. Schewela, *Guidelines for Community Noise*, World Health Organization, Geneva, 1999.
- [64] K. Persson Waye, E. Öhrström, “Psycho-acoustic characters of relevance for annoyance of wind turbine noise”, *Journal of Sound and Vibration*, 250 (1), 2002, 65-73.
- [65] K. Persson Waye, A. Agge, “Experimental quantification of annoyance unpleasant and pleasant wind turbine sounds”, *Proceedings of internoise*, 27—30, August 2000, Nice, France, pp. 3994-3997.
- [66] C. Guarnaccia, N. E. Mastorakis, J. Quartieri, “Wind Turbine Noise: Theoretical and Experimental Study”, *International Journal of Mechanics*, Issue 3, Vol. 5, pp.129-137, 2011.
- [67] A. Ruggiero, J. Quartieri, C. Guarnaccia, S. Hloch, *Noise Pollution Analysis of Wind Turbines in Rural Areas*, *International Journal of Environmental Research*, Vol. 9 (4), pp. 1277-1286, 2015.

- [68] J. Quartieri, A. Troisi, C. Guarnaccia, T.L.L. Lenza, P. D'Agostino, S. D'Ambrosio, G. Iannone, "Application of a Predictive Acoustical Software for Modelling Low Speed Train Noise in an Urban Environment", *WSEAS Transactions on Systems*, Issue 6 Vol.8, pp. 673-682, 2009.
- [69] J. Quartieri, A. Troisi, C. Guarnaccia, T.L.L. Lenza, P. D'Agostino, S. D'Ambrosio, G. Iannone, "An Acoustical Study of High Speed Train Transits", *WSEAS Transactions on Systems*, Issue 4, Vol.8, pp. 481-490, 2009.
- [70] C. Guarnaccia, J. Quartieri, A. Ruggiero, "Acoustical Noise Study of a Factory": Indoor and Outdoor Simulations Integration Procedure, *International Journal of Mechanics*, Vol. 8, pp. 298-306, 2014.
- [71] C. Guarnaccia, J. Quartieri, N.E. Mastorakis, "Analysis of Methods to Evaluate the Noise Reduction due to Acoustic Barriers Installation", *International Journal of Mechanics*, Vol. 8, pp. 258-267, 2014.
- [72] C. Guarnaccia, J. Quartieri, "Analysis of road traffic noise propagation", *International Journal of Mathematical Models and Methods in Applied Sciences*, Vol. 6 (8), pp. 926-933, 2012.
- [73] A.R. Finamore, V. Calderaro, V. Galdi, A. Piccolo, G. Conio, "A Wind Speed Forecasting Model Based on Artificial Neural Network and Meteorological Data", 16 IEEE International Conference on Environment and Electrical Engineering, Firenze, Italy, June 2016.
- [74] R.G. Kavasseri, K. Seetharaman, "Day-ahead wind speed forecasting using f-ARIMA models", *Renewable Energy*, 34 (2009) pp 1388-1393.
- [75] X. Wang, P. Guo, X. Huang, "A Review of Wind Power Forecasting Models", *Energy Procedia*, 12 (2011) pp 770-778.
- [76] E. Cadenas, W. Rivera, R. Campos-Amezcuca, C. Heard, "Wind Speed Prediction Using a Univariate ARIMA Model and a Multivariate NARX Model", *Energies*, 9,109 (2016).
- [77] Wagner S., Bareiß R., Guidati G., *Wind Turbine Noise*, Springer-Verlag, (1996).
- [78] Vestas doc 946506 Rev 10, 2008-10-08.
- [79] <http://www.ilmeteo.it/>
- [80] E.W. Peterson and J.P. Jr. Hennessey, "On the use of power laws for estimates of wind power potential", *J. Appl. Meteorology*, Vol. 17, (1978), pp. 390-394.
- [81] Directive 2002/49/EC of the European Parliament and of the Council of 25 June 2002 relating to the assessment and management of environmental noise.
- [82] Matthew E. Kahn, *Green Cities. Urban Growth and the Environment*, Environmental Conservation, Brookings Institution Press, Washington, DC, USA, 2006.
- [83] Miguel Cárdenas Rodríguez, Laura Dupont-Courtade, Walid Oueslati, *Air pollution and urban structure linkages: Evidence from European cities*, *Renewable and Sustainable Energy Reviews*, Volume 53, January 2016, Pages 1–9.
- [84] Paulo Eduardo Kirrian Fiedler, Paulo Henrique Trombetta Zannin, *Evaluation of noise pollution in urban traffic hubs—Noise maps and measurements*, *Environmental Impact Assessment Review*, Volume 51, February 2015, Pages 1–9.
- [85] T. Bodin, M. Albin, J. Ardö, E. Stroh, P.O. Östergren, J. Björk, "Road traffic noise and hypertension: results from a cross-sectional public health survey in southern Sweden", *Environmental Health* (2009), 8:38 doi:10.1186/1476-069X-8-38.
- [86] Paul Zhang, *Multiple Imputation: Theory and Method*, *International Statistical Review / Revue Internationale de Statistique*, Vol. 71, No. 3 (Dec. 2003), pp. 581-592.
- [87] G. P. Zhang, "Time series forecasting using a hybrid ARIMA and neural network model", *Neurocomputing*, 50 (2003), pp 159-175.
- [88] De Kluizenaar Y, Janssen SA, Van Lenthe FL, Miedema HME, Mackenbach JP. Long-term road traffic noise exposure associated with an increase morning tiredness. *J Acoust Soc Am* 2009;126:626–33.
- [89] De Kluizenaar Y, Salomons EM, Janssen SA, Van Lenthe FJ, Vos H, Zhou H, et al. Urban road traffic noise and annoyance: the effect of a quiet façade. *J Acoust Soc Am* 2011;130:1936–42.
- [90] Ouis D. Annoyance from road traffic noise: a review. *J Environ Psychol* 2001;21:101–20.

- [91] ENSTAT. NV1 – definition of noise and vibration terms. Downloaded from [www2.luton.gov.uk/NapierPark/Environmental\\_Statement/Appendices/Noise\\_and\\_Vibration/NV1.pdf](http://www2.luton.gov.uk/NapierPark/Environmental_Statement/Appendices/Noise_and_Vibration/NV1.pdf), on 14 May 2014.
- [92] Anon. Calculation of road traffic noise. London: United Kingdom Department of Environment and Welsh Office. HMSO; 1975.
- [93] United Kingdom Department of Transport. Calculation of road traffic noise. London: HMSO; 1988.
- [94] Barry TM, Regan J. Highway traffic noise prediction model. USA: FHWA-RD-77108; 1978.
- [95] US Department of Transport. FHWA traffic noise model. USA: FHWA-PD-96010; 1988.
- [96] Guarnaccia C, Quartieri J, Barrios JM, Rodrigues ER. Modeling environmental noise exceedances using non-homogeneous Poisson processes. *J Acoust Soc Am* 2014;136:1631–9. <http://dx.doi.org/10.1171/1.4895662>.
- [97] Achcar JA, Rodrigues ER, Paulino CD, Soares P. Non-homogeneous Poisson processes with a change-point: an application to ozone exceedances in Mexico City. *Environ Ecol Stat* 2010;17:521–41. <http://dx.doi.org/10.1007/s10651009-0114-3>.
- [98] Achcar JA, Rodrigues ER, Tzintzun G. Using non-homogeneous Poisson models with multiple change-points to estimate the number of ozone exceedances in Mexico City. *Environmetrics* 2011;22:1–12. <http://dx.doi.org/10.1002/env.1029>.
- [99] Wilson SP, Costello MJ. Predicting future discoveries of European marine species using non-homogeneous renewal processes. *J Royal Stat Soc Ser C* 2005;54:425–42.
- [100] Kass-Houter TA, Xu Z, McMurray P, Park S, Buckeridge DL, Brownstein JS, et al. Application of change-point analysis to daily influenza-like illness emergency department visits. *J Am Med Inform Assoc* 2012;19:1075–81. <http://dx.doi.org/10.1136/amiajnl-2011-000793>.
- [101] Chen J, Gupta AK. Parametric change-point analysis with applications to genetics, medicine, and finance. 2nd ed. New York: Springer; 2012.
- [102] Cox DR, Lewis PA. Statistical analysis of series of events. London: Methuen; 1966.
- [103] Lawless JF. Statistical models and methods for lifetime data. New York: John Wiley and Sons; 1982.
- [104] Rice JA. Mathematical statistics with data analysis. New York: Wadsworth and Brooks; 1988.
- [105] Carlin BP, Louis TA. Bayes and empirical Bayes methods for data analysis. 2<sup>nd</sup> ed. New York: Chapman and Hall/CRC; 2000.
- [106] Robert CR, Casella G. Monte Carlo statistical methods. New York: Springer; 1999.
- [107] Grimmett GR, Stirzaker DR. Probability and random processes. London: Clarendon Press; 1982.
- [108] Ross SM. Stochastic processes. 2nd ed. New York: John Wiley and Sons; 1996.
- [109] Achcar JA, Dey DK, Niverthy M. A Bayesian approach using non-homogeneous Poisson process for software reliability models. In: Basu SK, Mukhopadhyay S, editors. *Frontiers in reliability, series on quality, reliability and engineering statistics 4*, Calcutta University, India, 1998. p. 1–18. [http://dx.doi.org/10.1142/9789812816580\\_0001](http://dx.doi.org/10.1142/9789812816580_0001).
- [110] Achcar JA, Fernández-Bremauntz AA, Rodrigues ER, Tzintzun G. Estimating the number of ozone peaks in Mexico City using a non-homogeneous Poisson model. *Environmetrics* 2008;19:469–85. <http://dx.doi.org/10.1002/env.890>.
- [111] Ramírez-Cid JE, Achcar JA. Bayesian inference for nonhomogeneous Poisson processes in software reliability models assuming non-monotonic intensity functions. *Comput Stat Data Anal* 1999;32:147–59.
- [112] Álvarez LJ, Fernández-Bremauntz AA, Rodrigues ER, Tzintzun G. Maximum a posteriori estimation of the daily ozone peaks in Mexico City. *J Agric, Biol, Environ Stat* 2005;10:276–90. <http://dx.doi.org/10.1198/108571105X59017>.
- [113] Boys RJ, Henderson DA. On determining the order of Markov dependence of an observed process governed by a hidden Markov model. *Special Issue of Scient Program* 2002;10:241–51.
- [114] Churchill GA, Lazareva B. Bayesian restoration of a hidden Markov chain with applications to DNA sequencing. *J Comput Biol* 1999;6:261–77.

- [115] Geman D. Random fields and inverse problems in imaging. *Lecture Notes Math* 1990;1427:113–93.
- [116] Freston KJ, Glaser DE, Henson RNA, Kiebel S, Phillips C, Ashburner J. *NeuroImage. Classical and Bayesian inference in neuroimaging: applications* 2002;16:484–512. <http://dx.doi.org/10.1006/ning.2002.1091>.
- [117] Murshudov GN, Vagin AA, Dodson EJ. Refinement of molecular structure by maximum likelihood method. *Acta Cryst* 1997;D53:240–55.
- [118] Tamura K, Peterson D, Peterson N, Stecher G, Nei M, Kumar S. MEGA 5: molecular evolutionary genetics. Analysis using maximum likelihood, evolutionary distance, and maximum parsimony methods. *Mol Biol Evol* 2011;28:2731–9. <http://dx.doi.org/10.1093/molbev/msr121>.
- [119] Yang Z. PAML 4: phylogenetic analysis by maximum likelihood. *Mol Biol Evol* 2007;24:1586–91. <http://dx.doi.org/10.1009/molbev/msr088>.
- [120] Yang TE, Kuo L. Bayesian binary segmentation procedure for a Poisson process with multiple change-points. *J Comput Graph Stat* 2001;10:772–85. <http://dx.doi.org/10.1198/106186001317243449>.
- [121] Lunn D, Spiegelhalter D, Thomas A, Best N. The BUGS project: evolution, critique and future directions (with discussion). *Stat Med* 2010;28:3049–82.
- [122] ISO. ISO20906-2009. Acoustics – unattended monitoring of aircraft sound in the vicinity of airports; 2009. <[www.iso.org/iso/cataloguedetail?csnumber=3558](http://www.iso.org/iso/cataloguedetail?csnumber=3558)>.
- [123] DIN. DIN45643:2011-02. Measurement and assessment of aircraft sound; 2011. <[www.beuth.de/en/standard/din-45643/136846081](http://www.beuth.de/en/standard/din-45643/136846081)>.
- [124] Pessa E., *Statistica con le reti neurali*, Roma, Di Renzo Editore, 2004. ISBN 978-88-8323-074-5.
- [125] Haykin, Simon (1998). *Neural Networks: A Comprehensive Foundation* (2 ed.). Prentice Hall. ISBN 0-13-273350-1.
- [126] Beatrice Lazzarini, “Introduzione alle Reti Neurali”, Dipartimento di Ingegneria dell’Informazione, Università di Pisa.

*Per la stesura di questo elaborato si ritiene doveroso ringraziare:*

Il professore Joseph Quartieri per aver incoraggiato e sostenuto concretamente il percorso formativo dell'autore; il professore Claudio Guarnaccia per aver attivamente concorso all'impianto teorico e applicativo di questa ricerca scientifica; la professoressa Eliane R. Rodrigues per la precisa e puntuale collaborazione nello sviluppo dei modelli di Poisson non omogenei qui presentati; il Procuratore della Repubblica Amedeo Sessa per aver offerto all'autore la possibilità di affiancare alla formazione accademica l'applicazione professionale di quanto appreso in ambito ingegneristico in un contesto di eccezionale responsabilità sociale; il professore Stefano Riemma per aver contribuito ad aumentare l'interesse dell'autore verso le discipline economico-gestionali; il professore Vincenzo Galdi per aver offerto all'autore l'opportunità di accrescere la propria conoscenza sia dei fondamentali aspetti della produzione e gestione dell'energia che delle tecniche di soft-computing connesse. E' infine doveroso ringraziare gli amici e compagni dell'associazione StudentIngegneria con i quali si è instaurata una costruttiva amicizia e collaborazione. Infine un caloroso ringraziamento è dedicato al Prof. Ing. Vincenzo Sergi per la preziosa collaborazione nella fase iniziale e finale di questo percorso di studi e al carissimo Prof. Ing. Claudio Rafanelli per la dettagliata e precisa revisione dei contenuti e della forma di questo elaborato.

