


# UNIVERSITÀ DEGLI STUDI DI PADOVA DIPARTIMENTO DI SCIENZE STATISTICHE

Corso di Laurea Magistrale in Scienze Statistiche



MODELLI PER LA GESTIONE OTTIMIZZATA DELLE RISORSE ENERGETICHE  
RINNOVABILI: UN'ANALISI DEL CASO PORTOGHESE

*Relatore:* Prof. Emanuele ALIVERTI

Dipartimento di Scienze Statistiche

*Laureanda:* Maria GALLO

*Matricola:* 2023127

Anno Accademico 2022/2023



# Indice

<b>1. Introduzione</b>	<b>3</b>
<b>2. Materiali e metodi</b>	<b>6</b>
2.1 Dati sulla produzione energetica solare ed eolica in Portogallo . . . . .	6
2.2 Modelli di Previsione per Serie Temporali . . . . .	11
2.2.1 Modello di Regressione con Errori ARMA . . . . .	11
2.2.2 Prophet . . . . .	12
2.2.3 NeuralProphet . . . . .	14
2.2.4 Reti Neurali Ricorrenti . . . . .	18
2.2.5 Reti Neurali LSTM . . . . .	20
2.2.6 Reti Neurali GRU . . . . .	24
2.3 Metriche per il Confronto . . . . .	25
<b>3. Analisi Empiriche</b>	<b>27</b>
3.1 Risultati per il Modello di Regressione con Errori ARMA . . . . .	29
3.2 Risultati per il Modello Prophet . . . . .	31
3.3 Risultati per il modello NeuarlProphet . . . . .	34
3.4 Risultati per il Modello RNN . . . . .	36
3.5 Risultati per il Modello LSTM . . . . .	40
3.6 Risultati per il Modello GRU . . . . .	42
3.7 Analisi Comparativa dei Risultati . . . . .	44
<b>4. Integrazione di Energie Rinnovabili ed Energie Nucleari in un Contesto Pratico</b>	<b>50</b>

<b>5. Conclusioni</b>	<b>60</b>
<b>6. Appendice</b>	<b>63</b>
<b>6. Bibliografia</b>	<b>81</b>



# 1. Introduzione

Lo scenario energetico mondiale è un quadro complesso e in continua evoluzione che comprende la produzione, la distribuzione e l'uso delle risorse energetiche in tutto il mondo. L'energia è fondamentale per alimentare l'industria, il trasporto, le infrastrutture e la vita quotidiana, e le sue fonti sono varie e diversificate. Diverse classificazioni delle fonti energetiche sono state proposte nel corso degli anni. Tuttavia la suddivisione che più si adatta a questo studio prevede una classificazione delle fonti in base alla loro esauribilità. Le fonti energetiche possono quindi essere suddivise in fonti energetiche rinnovabili, cioè fonti energetiche non esauribili, e non rinnovabili, cioè fonti energetiche esauribili. Tra le fonti energetiche rinnovabili troviamo l'energia solare, eolica, geotermica, idroelettrica e biomassa, mentre fanno parte di quelle non rinnovabili i combustibili fossili (petrolio, carbone, gas naturale) e nucleari (uranio) (European Parliament, 2018). Negli ultimi anni, specialmente a seguito dell'accordo di Parigi del 2015 («Accordo di Parigi sui cambiamenti climatici», 2015), la transizione verso fonti di energia sostenibile e rinnovabile riveste un ruolo sempre più centrale nella riduzione delle emissioni di carbonio e nella promozione di un futuro energetico più sostenibile ed efficiente. Recentemente, le fonti rinnovabili su cui si sono concentrati i maggiori sforzi di sviluppo sono le fonti energetiche rinnovabili solare ed eolico. Tuttavia, la produzione di energia solare ed eolica è fortemente influenzata da variabili meteorologiche in continua evoluzione, rendendo la previsione di tali produzioni una sfida complessa ma fondamentale per una gestione ottimale delle risorse energetiche. La necessità di prevedere con precisione la produzione energetica rinnovabile è ancor più evidente quando si considera l'obiettivo di bilanciare e regolare la produzione di energia proveniente da tecnologie alternative, come l'energia nucleare, in modo da adeguarsi alle esigenze della rete elettrica in tempo reale (OECD e Nuclear Energy Agency, 2012). Il presente lavoro si concentra su questa sfida cruciale, con l'obiettivo di analizzare

e valutare diversi modelli di previsione per serie storiche, confrontando le loro performance nella previsione della produzione di energia proveniente da fonti rinnovabili in Portogallo. Il Portogallo si sta infatti muovendo verso un futuro energetico basato principalmente su fonti rinnovabili: ad agosto 2023, il 68.3% dell'energia elettrica generata proviene da tali fonti e nello specifico il 9.3% proviene da impianti solari mentre il 29% da impianti eolici («REN - Redes Energéticas Nacionais», 2023). Proprio per l'attuale forte interesse al riguardo, e per l'importanza che rivestono nel garantire una stabilità nell'approvvigionamento energetico in Portogallo, le serie storiche giornaliere della potenza di produzione di energia solare e di energia eolica sono state selezionate come oggetto di studio.

Per affrontare questa sfida, sono stati esaminati diversi modelli di previsione, nello specifico: il modello di regressione con errori autoregressivi a media mobile (ARMA), Prophet, NeuralProphet, un modello di rete neurale ricorrente (RNN), e due varianti di modelli di RNN chiamati Long Short-Term Memory (LSTM) e Gated Recurrent Unit (GRU). Il primo modello analizzato in questo lavoro è una variante del modello ARIMA, il quale storicamente è stato il modello di previsione più popolare nell'industria finanziaria e nella domanda di mercato (Almasarweh e Wadi, 2018). Il secondo modello preso in esame è il modello Prophet, tale modello consiste in un nuovo approccio di previsione sviluppato da Facebook nel 2018 e ha dimostrato una buona accuratezza di previsione quando applicato a serie storiche con forti effetti stagionali (Aditya Satrio et al., 2021). Inoltre, confrontato con modelli alternativi, richiede un'ottimizzazione minore degli iperparametri e serie storiche meno ampie in termini di numerosità di osservazioni. Il terzo modello, NeuralProphet, può essere visto come un'estensione del modello Prophet, del quale conserva i vantaggi. NeuralProphet combina, da una parte, la scalabilità delle reti neurali con, dall'altra, l'interpretabilità dei modelli autoregressivi (AR). In altre parole, NeuralProphet introduce una rete neurale autoregressiva chiamata AR-Net col fine di migliorare la sua accuratezza e scalabilità (Triebe et al., 2021). I restanti tre modelli analizzati in questo lavoro sono RNN, LSTM e GRU, questi fanno parte della famiglia delle reti neurali ricorrenti. Queste ultime sono ben note e ampiamente utilizzate per la previsione di serie storiche nella letteratura (Zhang, 2003). RNN, LSTM e GRU sono modelli caratterizzati dal cosiddetto apprendimento profondo (*deep learning*). Questi modelli sono infatti composti da livelli multipli di unità non lineari in grado di offrire una

migliore modellazione dei comportamenti temporali complessi e non lineari. Nello specifico i modelli GRU e LSTM sono RNN ideate con lo scopo di risolvere l'instabilità del gradiente di cui soffre il modello classico RNN (Hochreiter e Schmidhuber, 1997).

Il presente lavoro di tesi può essere suddiviso in due parti principali. Nella prima parte la stima dei modelli presi in esame è stata condotta utilizzando una vasta gamma di variabili esogene, che comprende variabili meteorologiche provenienti da nove diverse città portoghesi e la capacità installata complessiva degli impianti energetici. Questo approccio completo mira ad identificare il modello più efficace per prevedere la produzione energetica da fonti rinnovabili, consentendo così una regolazione ottimale della produzione di energia a partire da fonti programmabili, come per esempio l'energia nucleare, con il fine di soddisfare le esigenze del sistema elettrico. Nella fase iniziale di questa analisi vengono esaminati in dettaglio i dati e i modelli scelti per la previsione della potenza di produzione energetica solare ed eolica. Successivamente, si procede con la discussione dei risultati derivanti dall'applicazione dei modelli basati sulle variabili meteorologiche osservate, identificando il modello più accurato per ciascuna delle due serie oggetto di studio. Nella seconda parte di questo lavoro di tesi, l'attenzione si sposta sull'applicazione dei migliori modelli in un contesto pratico, in cui le osservazioni meteorologiche vengono sostituite con i valori previsti con un giorno d'anticipo. L'obiettivo è esaminare come questa sostituzione influisca sull'accuratezza delle previsioni.

Attraverso questa analisi, si mira così a contribuire in modo significativo alla ricerca nel campo delle previsioni energetiche e a fornire soluzioni pratiche per la gestione efficiente delle risorse energetiche rinnovabili.






## 2. Materiali e metodi

### 2.1 Dati sulla produzione energetica solare ed eolica in Portogallo

Per condurre l'analisi delineata nell'introduzione, è stato scelto di investigare i dati energetici relativi al Portogallo. Il Portogallo, infatti, è uno dei paesi europei più impegnati nella transizione energetica verso fonti rinnovabili e nella riduzione delle emissioni di gas serra: è stato tra i primi paesi al mondo a fissare un obiettivo di neutralità climatica entro il 2050 (International Energy Agency, 2021). Per raggiungere questo obiettivo, la previsione della produzione energetica rinnovabile assume un'importanza fondamentale per garantire la stabilità dell'approvvigionamento elettrico durante e successivamente tale transizione.

Il Portogallo si trova nella penisola Iberica, ha una superficie totale di 92.225 chilometri quadrati («Statistics Portugal - Web Portal», 2023) e, con riferimento alla classificazione climatica di Köppen (Köppen, 1900), il clima può essere classificato come di tipo Mediterraneo con estati fresche e secche (Csb) nel Nord del territorio e Mediterraneo con estati calde e secche (Csa) nel Sud (Peel et al., 2007). Le due aree del Paese mostrano contrasti climatici significativi: il primo, rispetto al secondo, è caratterizzato da una maggiore presenza di umidità e di venti e da un minore livello di radiazione solare (Mora e Vieira, 2020). Grazie a queste differenze, nonostante le dimensioni relativamente ridotte del territorio, è presente una sostanziale variabilità spaziale in termini di velocità dei venti e radiazione solare (Santos-Alamillos et al., 2012). Il Portogallo ha potuto sfruttare al meglio le differenze climatiche tra le due aree posizionando in maniera strategica centrali solari ed eoliche: come si nota da Figura 1 gli impianti fotovoltaici, di cui vengono rappresentati solo quelli con una capacità

installata superiore a 1 MW, sono maggiormente concentrati nel Sud del Paese, a differenza delle centrali eoliche concentrate principalmente nel Nord. Attualmente l'energia eolica e quella solare sono tra le principali fonti di energia rinnovabile del Portogallo, insieme all'energia idrica e alla bioenergia («APREN - Production», 2023). Complessivamente, a settembre 2023, gli impianti eolici hanno una capacità installata totale pari a 5374 MW e quelli solari pari a 2340 MW («REN - Redes Energéticas Nacionais», 2023).



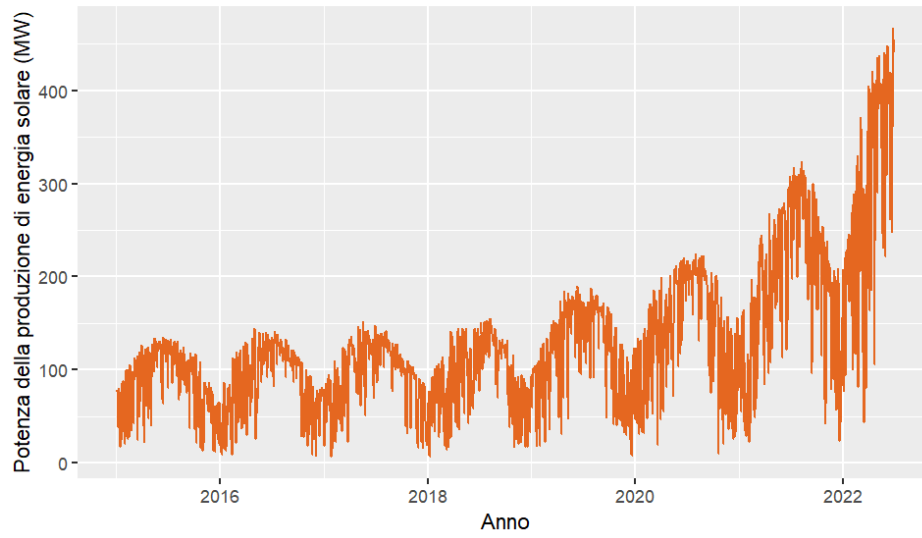
**Figura 1:** (a): mappa degli impianti fotovoltaici con capacità installata superiore a 1 MW in Portogallo. (b): mappa degli impianti eolici in Portogallo. (Marzo 2023).

Fonte: «e2p - endogenous energies of Portugal», 2023.


I dati sulla produzione di energia solare ed eolica in Portogallo sono stati ricavati attraverso il sito [transparency.entsoe.eu](https://transparency.entsoe.eu). Da questa piattaforma è stato possibile scaricare le serie temporali a frequenza oraria dal 1 gennaio 2015 01:00 al 31 dicembre 2022 00:00 delle variabili *Solar*, *Wind Offshore* e *Wind Onshore*. Queste rappresentano la potenza media oraria, espressa in MW, con cui vengono prodotte energia solare, energia eolica offshore ed energia eolica onshore relative a tutto il territorio nazionale. Per analizzare la potenza di produzione di energia eolica si è scelto di non considerare la differenza tra energia eolica prodotta da impianti offshore ed onshore, di conseguenza le due variabili sono state accorpate tramite

una somma dei valori relativi allo stesso istante temporale. In seguito, le serie temporali sono state trasformate in modo tale da ottenere le serie a frequenza giornaliera, calcolando la media delle potenze orarie appartenenti allo stesso giorno ed ottenendo così la potenza media giornaliera. Successivamente, entrambe sono state divise in due sezioni: la prima sezione, relativa al periodo 1 gennaio 2015 - 30 giugno 2022, comprende 2738 osservazioni ed è adibita alla stima dei modelli (*training set*); la seconda sezione, relativa al periodo 1 luglio 2022 - 31 dicembre 2022, è costituita da 184 osservazioni ed è dedicata alla valutazione dell'accuratezza dei modelli (*testing set*). Le prime due sezioni delle serie di potenza media giornaliera con cui vengono generate energia solare ed energia eolica sono rappresentate rispettivamente in Figura 2 e Figura 3. Al fine di migliorare la performance dei modelli sono state incluse nell'analisi alcune variabili esogene, nello specifico variabili meteorologiche e variabili relative alla capacità installata totale degli impianti eolici e degli impianti solari. Sono state considerate unicamente le variabili meteorologiche che, in accordo con la letteratura scientifica, influenzano la produzione delle energie rinnovabili in analisi. Per quanto concerne la serie temporale della potenza di produzione di energia eolica, sono state considerate la temperatura a due metri dal suolo, la pressione atmosferica a livello del mare e la velocità del vento a 100 metri dal suolo. La produzione di energia eolica è infatti legata alla velocità del vento e alla densità dell'aria: quest'ultima è una funzione della pressione atmosferica e della temperatura (El-Ahmar et al., 2017). Per quanto riguarda la serie temporale della potenza di produzione di energia solare, sono state considerate la temperatura a due metri dal suolo, l'irradiazione solare e la copertura nuvolosa. La produzione di energia solare è infatti dipendente da tali variabili meteorologiche (Chikate, 2015). I valori medi giornalieri delle cinque variabili sopraelencate sono stati ricavati come serie temporali giornaliere dal 1 gennaio 2015 al 31 dicembre 2022 dal sito open-meteo.com, che permette di selezionare una località geografica e ottenere lo storico dei dati meteorologici per un intervallo temporale a scelta. Per questa analisi sono state selezionate le variabili: *Temperature (2 m)*, *Sealevel Pressure*, *Direct Normal Irradiance (DNI)*, *Cloudcover Total* e *Wind Speed (100 m)*, per nove città. Le città sono state scelte in modo tale da coprire il territorio portoghese con la maggiore concentrazione di impianti eolici e solari. Le città prese in considerazione sono: Castelo Branco, Evora, Faro, Guarda, Leiria, Lisbona, Porto, Santarém e Vila Real, di cui è rappresentato il posizionamento geografico in

Figura A1. Al fine di visualizzare le differenze climatiche tra le località selezionate in termini delle variabili meteorologiche scelte, in Figura A2, Figura A3, Figura A4, Figura A5 e Figura A6, sono rappresentate le serie dei dati meteorologici lisciati tramite *loess*. Si è ritenuto inoltre importante tenere in considerazione le capacità installate totali degli impianti eolici e fotovoltaici, in quanto governano la potenza di produzione di energia eolica e solare. I valori annuali delle capacità totali installate dal 2015 al 2022 sono stati scaricati tramite il sito [transparency.entsoe.eu](https://transparency.entsoe.eu). Dal momento che vengono resi disponibili i dati su base annuale, al fine di ottenere le serie a frequenza giornaliera, si è deciso di trasformare i dati secondo la procedura descritta di seguito. Le serie temporali a frequenza giornaliera sono state ottenute inizialmente ripetendo i dati annuali di capacità installata per ogni giorno del corrispettivo anno. Successivamente su queste serie viene applicata una media mobile con ampiezza della finestra scorrevole pari a 365. Poiché la media mobile non fornisce i valori relativi alle prime e alle ultime 182 osservazioni, a queste sono state assegnati i valori della capacità installata totale relativa al 2015 e al 2022 rispettivamente. Infine, i valori forniti dalla media mobile sono stati approssimati all'intero più vicino. Le serie risultanti sono raffigurate in Figura A7 e Figura A8, rispettivamente per la capacità installata degli impianti solari e di quelli eolici. Queste trasformazioni delle serie temporali sono state eseguite al fine di rappresentare in maniera realistica la distribuzione dell'installazione di nuovi impianti solari ed eolici negli anni in considerazione. Tale adattamento è stato necessario considerando l'importante ruolo svolto da tale variabile nella produzione energetica ed è fondamentale riconoscere che, se queste modifiche dovessero rivelarsi imprecise, potrebbero avere un impatto negativo sulla capacità predittiva dei modelli stimati.



**Figura 2:** Potenza media giornaliera della produzione di energia solare in Portogallo, 1 gennaio 2015 - 30 giugno 2022.



**Figura 3:** Potenza media giornaliera della produzione di energia eolica in Portogallo, 1 gennaio 2015 - 30 giugno 2022.

## 2.2 Modelli di Previsione per Serie Temporali

In questa sezione vengono presentati in maniera formale i diversi modelli utilizzati per prevedere la potenza di produzione giornaliera di energia eolica e di energia solare, al fine di cogliere gli aspetti essenziali che caratterizzano e distinguono ciascun metodo di stima.

### 2.2.1 Modello di Regressione con Errori ARMA

Nell'analisi delle serie storiche, un modello di regressione con errori che seguono un processo autoregressivo a media mobile (ARMA) è un modello che incorpora variabili esogene ed errori con una struttura di correlazione seriale. L'idea di base è quella di usare un modello di regressione per spiegare le variazioni della variabile dipendente come funzione di una o più variabili indipendenti, e adattare un modello ARMA alla serie degli errori. Il modello può essere rappresentato come:

$$y_t = f(X_t, \beta) + z_t, \quad (1)$$

dove  $y_t$  è la serie temporale d'interesse,  $z_t$  è la serie degli errori,  $X_t$  rappresenta l'insieme delle variabili esogene,  $\beta$  è un vettore di parametri e  $f(X_t, \beta)$  rappresenta l'effetto dell'input  $X_t$  sull'output  $y_t$ . Nella definizione del modello si assume che il processo non osservato  $z_t$  in Equazione (1) segua un processo ARMA stazionario o non stazionario, che può essere rappresentato nella forma:

$$\Phi(B)z_t = \theta(B)a_t, \quad (2)$$

con  $\Phi(B) = U(B)\phi(B)$ , dove  $\Phi(B) = 1 - \Phi_1 B - \dots - \Phi_p B^p$ ,  $U(B) = 1 - U_1 B - \dots - U_d B^d$ ,  $\phi(B) = 1 - \phi_1 B - \dots - \phi_{p-d} B^{p-d}$ , e  $\theta(B) = 1 - \theta_1 B - \dots - \theta_q B^q$  sono polinomi in  $B$ , dove  $B$  è l'operatore di ritardo e  $a_t$  è un processo *white noise*, ossia una sequenza di variabili indipendenti con media nulla e varianza finita (Box, 1970). Se  $f(X_t, \beta) = \sum_{i=1}^k \beta_i X_{it}$ , il modello definito in Equazione (1) è lineare e può essere scritto nella forma:

$$y_t = \sum_{i=1}^k \beta_i X_{it} + [\Phi(B)]^{-1} \theta(B) a_t. \quad (3)$$

I parametri  $\beta$ ,  $\Phi_i$  e  $\theta_j$  vengono stimati simultaneamente e la loro stima può essere ottenuta sia utilizzando il metodo della massima verosimiglianza sia i minimi quadrati pesati (Tsay, 1984). In conclusione, per quanto concerne la selezione del modello, tra i metodi più utilizzati

per l'identificazione degli ordini  $p$  e  $q$  dei termini autoregressivo e a media mobile, i quali non sono noti a priori, si trovano l'analisi della funzione di autocorrelazione (ACF) e della funzione di autocorrelazione parziale (PACF), e l'utilizzo di criteri d'informazione. Nello specifico, attraverso lo studio grafico delle ACF e delle PACF della serie temporale in analisi è possibile stabilire gli ordini del modello (Box et al., 2015). In alternativa, l'utilizzo di criteri d'informazione come il criterio d'informazione di Akaike (AIC) o la sua versione corretta (AICc) possono essere utilizzati per tale selezione (Brockwell e Davis, 2009).

## 2.2.2 Prophet

Il modello Prophet è un modello di previsione per serie storiche sviluppato da Facebook. È stato concepito per gestire alcune caratteristiche comuni delle serie di ambito aziendale, ovvero la presenza di variazioni nel trend e la stagionalità. Si basa su un modello scomponibile con tre componenti principali: trend, stagionalità e festività. Queste sono combinate additivamente nel modo seguente:

$$y_t = g_t + s_t + h_t + \epsilon_t, \quad (4)$$

dove  $g_t$  è la funzione trend che modella variazioni non periodiche nei valori della serie,  $s_t$  rappresenta cambiamenti periodici,  $h_t$  rappresenta l'effetto delle festività e  $\epsilon_t$  è il termine d'errore con distribuzione normale. La procedura prevede l'adattamento di una curva ai dati che, a differenza dei modelli per serie storiche, non tiene conto in maniera esplicita della struttura di dipendenza temporale dei dati, ossia non esplicita la relazione tra  $y_t$  e  $y_{t-1}$ . Questa scelta porta con sé diversi vantaggi tra cui una maggiore flessibilità e una procedura di adattamento più rapida. Per quanto concerne la componente di trend  $g_t$ , il modello Prophet permette la scelta tra due diverse specificazioni in modo da garantire una maggiore adattabilità a diverse applicazioni. Queste sono il modello di crescita non lineare e il modello lineare a tratti. Il modello di crescita non lineare fa riferimento alla crescita della popolazione in ecosistemi naturali, dove si ha una crescita non lineare che satura ad una certa capacità. Questo tipo di crescita è spesso modellato usando il modello logistico di crescita, che nella sua forma più semplice è rappresentato come:

$$g_t = \frac{C}{(1 + \exp(-k(t - m)))}, \quad (5)$$



dove  $C$  è la capacità,  $k$  è il tasso di crescita e  $m$  è un parametro *offset*. Questa specificazione può essere generalizzata in maniera tale che sia più rappresentativa possibile del fenomeno in analisi: è possibile incorporare sia una capacità che un tasso di crescita variabili nel tempo. Nel primo caso si sostituisce  $C$  con  $C_t$  che rappresenta una capacità variabile nel tempo, nel secondo è sufficiente stabilire dei *changepoint* in cui il tasso di crescita cambia. Supponiamo di avere  $S$  *changepoint* al tempo  $s_j$  con  $j = 1, \dots, S$ , si definisce un vettore di aggiustamenti del tasso di crescita  $\delta \in \mathbb{R}^S$ , dove  $\delta_j$  è la variazione nel tasso di crescita all'istante  $s_j$ . Il tasso al tempo  $t$  è il tasso di crescita base  $k$  più tutti gli aggiustamenti fino all'istante  $t$ :  $k + \sum_{j:t>s_j} \delta_j$ . Per il modello logistico di crescita quindi il tasso di crescita al tempo  $t$  corrisponde a  $k + a_t^T \delta$ , dove  $a_t \in \{0, 1\}^S$  è un vettore definito nel modo seguente:

$$a_{jt} = \begin{cases} 1, & \text{se } t \geq s_j \\ 0, & \text{altrimenti.} \end{cases} \quad (6)$$

Tale modello può essere espresso nella forma:

$$g_t = \frac{C_t}{(1 + \exp(-(k + a_t^T \delta)(t - (m + a_t^T \gamma))))}, \quad (7)$$

dove  $\gamma$  è un parametro scelto per connettere i punti estremi dei segmenti. Come detto in precedenza l'alternativa al modello logistico di crescita è il modello lineare a tratti, il quale prevede che il tasso di crescita sia costante a tratti. In questo caso il modello per il trend può essere scritto nella forma seguente:

$$g_t = (k + a_t^T \delta)t + (m + a_t^T \gamma), \quad (8)$$

dove come prima  $k$  è il tasso di crescita,  $\delta$  contiene gli aggiustamenti del tasso e  $m$  è il parametro *offset*. Sia per il modello logistico di crescita che per il modello lineare a tratti la scelta dei *changepoint*  $s_j$  può essere specificata oppure può essere fatta automaticamente a partire da un insieme di valori, scegliendo per  $\delta$  una distribuzione a priori sparsa come, ad esempio, la distribuzione Laplace:  $\delta_j \sim \text{Laplace}(0, \tau)$ . La componente stagionale viene specificata attraverso funzioni periodiche di  $t$ . Indicando con  $P$  il periodo regolare che ci si aspetta abbia la serie, è possibile approssimare l'effetto stagionale con:

$$s_t = \sum_{n=1}^N \left( a_n \cos\left(\frac{2\pi nt}{P}\right) + b_n \sin\left(\frac{2\pi nt}{P}\right) \right), \quad (9)$$

ossia una serie di Fourier standard con  $N$  termini. La componente stagionale richiede la stima di  $2N$  parametri  $\beta = [a_1, b_1, \dots, a_N, b_N]^T$  e si assume  $\beta \sim \text{Normale}(0, \sigma^2)$ . La presenza delle festività può essere rilevante per la serie temporale in analisi e l’impatto di una specifica festività è simile anno dopo anno. Si considera per ogni festività  $i$  la lista delle date passate e future  $D_i$  e viene aggiunta una funzione indicatrice che indica se l’istante temporale  $t$  coincide con una delle date in  $D_i$ . Ad ogni festività viene assegnato un parametro  $\kappa_i$  che rappresenta la variazione nei valori osservati della serie dovuta alla festività. Come per la stagionalità, si impone  $\kappa \sim \text{Normale}(0, v^2)$ . Inoltre, se necessario, il modello Prophet permette di includere delle variabili esogene in maniera additiva durante la fase di specificazione del modello. Per quanto concerne la stima dei parametri, questa coincide con una stima a posteriori ottenuta tramite l’algoritmo L-BFGS (Liu e Nocedal, 1989). I parametri di regolarizzazione  $\tau$ ,  $\sigma$  e  $v$ , che regolano la flessibilità nel trend, l’effetto della stagionalità e delle festività rispettivamente, possono essere identificati tramite una procedura di convalida incrociata. (Taylor e Letham, 2017).

### 2.2.3 NeuralProphet

NeuralProphet è un’estensione del modello Prophet di cui mantiene i vantaggi combinando la scalabilità delle reti neurali e l’interpretabilità dei modelli autoregressivi. Come per Prophet, un concetto fondamentale per il modello NeuralProphet è la sua composizione modulare: ogni modulo contribuisce in maniera additiva alla previsione. Questo modello può essere formalizzato come di seguito:

$$y_t = g_t + s_t + h_t + f_t + a_t + l_t, \quad (10)$$

dove  $g_t$  rappresenta il trend,  $s_t$  rappresenta l’effetto stagionale,  $h_t$  racchiude l’effetto delle festività,  $f_t$  costituisce l’effetto di regressione per variabili esogene note ad istanti temporali futuri,  $a_t$  rappresenta l’effetto autoregressivo e  $l_t$  costituisce l’effetto di regressione per variabili esogene ritardate. Tutti i moduli che compongono il modello possono essere configurati individualmente e combinati per costruire il modello. Un modo classico per modellare la componente trend consiste nella combinazione di un parametro *offset*  $m$  e di un tasso di crescita  $k$ . L’effetto del trend al tempo  $t_1$  si ottiene moltiplicando il tasso di crescita per la

differenza di tempo tra  $t_1$  e il tempo d'inizio  $t_0$ , sommato al parametro *offset*  $m$ :

$$g_{t_1} = m + k(t_1 - t_0). \quad (11)$$

La forma del trend può inoltre essere generalizzata definendo un tasso di crescita e un parametro *offset* variabili nel tempo, i cui valori variano in un certo numero di istanti temporali definiti *change point*. Il modello fornisce una procedura semi automatica per la selezione dei *change point* rilevanti. La stagionalità viene gestita tramite l'utilizzo della serie di Fourier. Per ogni effetto stagionale viene definito un numero di termini  $k$  della serie di Fourier con periodicità  $p$ :

$$s_{pt} = \sum_{j=1}^k \left( a_j \cos\left(\frac{2\pi jt}{p}\right) + b_j \sin\left(\frac{2\pi jt}{p}\right) \right), \quad (12)$$

dove  $k$  assume valori scelti al variare di  $p$ . L'effetto di tutte le stagionalità viene poi rappresentato dalla quantità  $s_t$  definita come:

$$s_t = \sum_{p \in \mathbb{P}} s_{pt}^*, \quad (13)$$

dove  $s_{pt}^*$  corrisponde a  $s_{pt}$  se la stagionalità ha un effetto additivo, oppure corrisponde a  $g_t s_{pt}$  se si sceglie di imporre un effetto moltiplicativo. Per specificare il modulo  $h_t$  delle festività, ogni evento è rappresentato da una variabile binaria  $e \in [0, 1]$ , che segnala se quell'evento cade in uno specifico istante temporale. Per un insieme di eventi  $\mathbb{E} \in \mathbb{R}^{T \times n_e}$ , con  $n_e$  il numero di eventi e  $T$  la lunghezza della serie, l'effetto di tutti gli eventi al tempo  $t$  viene rappresentato con:

$$h_t = \sum_{e \in \mathbb{E}} h_{et}^*. \quad (14)$$

Anche in questo caso, come nel precedente, è possibile scegliere se l'effetto della componente  $h_t$  sia additivo o moltiplicativo. Nello specifico,  $h_{et}^*$  viene posto uguale a  $h_{et}$  se si impone un effetto additivo, in alternativa è posto uguale a  $g_t h_{et}$  se si impone un effetto moltiplicativo, dove  $h_{et} = z_e e_t$ , e  $z_e$  denota il coefficiente del modello corrispondente all'evento  $e$ . Per modellare l'effetto di variabili esogene, rappresentate dal modulo  $f_t$ , è necessario conoscere il loro valore sia ad istanti temporali passati che futuri. Dato un insieme di regressori  $\mathbb{F} \in \mathbb{R}^{T \times n_k}$ , dove  $n_k$  è il numero di regressori, l'effetto di tutti i regressori al tempo  $t$  viene indicato con:

$$f_t = \sum_{k \in \mathbb{F}} f_{kt}^*. \quad (15)$$

Di base l'effetto dei regressori è additivo, ma questo può essere cambiato in moltiplicativo:  $f_{kt}^*$  è posto uguale a  $f_{kt}$  se si impone un effetto additivo, altrimenti è posto uguale a  $g_t f_{kt}$  se si impone un effetto moltiplicativo, dove  $f_{kt} = d_k k_t$ , e  $d_k$  rappresenta il coefficiente per il regressore  $k$ . Il modulo autoregressivo (AR) nel modello NeuarlProphet si basa su una versione modificata di AR-Net (Triebe et al., 2019). In ogni configurazione, le ultime  $p$  osservazioni della variabile d'interesse  $y_{t-1}, y_{t-2}, \dots, y_{t-p}$  sono gli input del modulo. Gli output sono  $h$  valori corrispondenti agli effetti AR per ciascun passo di previsione  $a_t^t, a_{t+1}^t, \dots, a_{t+h-1}^t$ , dove  $h$  corrisponde all'orizzonte di previsione. Di conseguenza,  $a_{t+2}^t$  denota l'effetto AR previsto per prevedere  $y_{t+2}$  all'origine della previsione  $t$  con dati osservati fino a  $t - 1$ .

$$a_t^t, a_{t+1}^t, \dots, a_{t+h-1}^t = \text{AR-Net}(y_{t-1}, y_{t-2}, \dots, y_{t-p}) \quad (16)$$

Il parametro più importante da fissare per questo modulo è l'ordine  $p$  del modello  $\text{AR}(p)$ . Il valore di  $p$  è difficile da determinare con accuratezza ed è comunemente posto uguale al doppio della periodicità più corta o al doppio dell'orizzonte di previsione. La configurazione base di AR-Net non contiene strati latenti ed è funzionalmente identica ad un modello AR. Corrisponde in pratica ad un rete neurale con un singolo strato, con  $p$  variabili di input,  $h$  variabili di output e senza una funzione di attivazione. Quando vengono configurati strati latenti, il modulo AR basato su AR-Net è in grado di modellare dinamiche non lineari. In questo caso il modulo stima una rete neurale completamente connessa con un numero specifico di strati latenti e nodi. Le ultime  $p$  osservazioni costituiscono gli input del primo strato. La funzione di attivazione tra lo strato di input e il primo strato latente è la *Rectified Lienar Unit* (ReLU), così come per ogni strato latente e quello ad esso precedente. Lo strato finale fornisce  $h$  output che non passano attraverso alcuna funzione di attivazione. Infine, i regressori ritardati vengono utilizzati per legare delle covariate alla serie temporale d'interesse. A differenza dei regressori futuri rappresentati dal modulo  $f_t$ , i valori futuri di queste covariate ritardate sono sconosciuti. All'istante di previsione  $t$ , si ha accesso esclusivamente ai loro valori passati fino all'istante  $t - 1$ .

$$l_t = \sum_{x \in \mathbb{X}} l_x(x_{t-1}, x_{t-2}, \dots, x_{t-p}). \quad (17)$$

Dato un insieme di covariate  $\mathbb{X} \in \mathbb{R}^{T \times n_u}$  viene creato un modulo di regressione ritardato per ognuna delle  $m$  covariate  $x$  di lunghezza  $T$ . Ogni modulo di regressione ritardato è funzio-

nalmente identico al modulo AR, con la differenza che gli input sono le ultime  $p$  osservazioni della covariata  $x$ . Ogni modulo produce  $h$  componenti additive  $l_{xt}^t, l_{xt+1}^t, \dots, l_{xt+h-1}^t$  per le previsioni finali  $\hat{y}_t, \hat{y}_{t+1}, \dots, \hat{y}_{t+h-1}$ :

$$l_{xt}^t, l_{xt+1}^t, \dots, l_{xt+h-1}^t = \text{AR-Net}(x_{t-1}, x_{t-2}, \dots, x_{t-p}). \quad (18)$$

Ogni considerazione riguardante l'ordine dei moduli AR-Net per ogni covariata sono identiche a quelle fatte per il modulo AR. Per quanto riguarda la procedura di stima del modello NeuralProphet, questa si basa su una versione moderna del *mini-batch stochastic gradienti descent* (SGD). Ogni componente del modello che viene stimata con SGD può essere inclusa come modulo. La funzione di perdita è la funzione di perdita Huber, conosciuta come *smooth L1-loss*, riportata in Equazione 19.

$$L_{huber}(y, \hat{y}) = \begin{cases} \frac{1}{2\beta} \sum_{t=1}^n (y_t - \hat{y}_t)^2, & \text{per } \sum_{t=1}^n |y_t - \hat{y}_t| < \beta \\ \sum_{t=1}^n |y_t - \hat{y}_t| - \frac{\beta}{2}, & \text{altrimenti} \end{cases} \quad (19)$$

Questa funzione di perdita, per valori sotto ad una soglia  $\beta$  corrisponde all'errore quadratico medio (MSE), per valori superiori a  $\beta$  corrisponde invece all'errore assoluto medio (MAE). Rispetto alla funzione di perdita MSE è meno sensibile ad *outliers* e previene inoltre "l'esplosione" del gradiente. Di base  $\beta$  è fissato pari ad 1. Come funzione di regolarizzazione viene utilizzata una log-trasformazione scalata del valore assoluto dei pesi del modello. Per un modulo con pesi del modello  $\theta$ , la funzione di regolarizzazione è parametrizzata come di seguito:

$$\Lambda(\theta, \epsilon, \alpha) = \frac{1}{n} \sum_{i=1}^n \log\left(\frac{1}{\epsilon e} + \alpha |\theta_i|\right) + \log(\epsilon) + 1, \quad (20)$$

dove  $\epsilon \in (0, \infty)$  e  $\alpha \in (0, \infty)$ . Il parametro  $\epsilon$  può essere interpretato come il parametro che regola la sparsità dei pesi, mentre il parametro  $\alpha$  può essere interpretato come il parametro che regola la grandezza dei pesi. Per la maggior parte delle applicazioni, gli autori suggeriscono l'utilizzo di  $\epsilon = 1$  e  $\alpha = 1$ . La regolarizzazione, dopo essere stata applicata, viene sommata alla funzione di perdita per essere propagata all'indietro. (Triebe et al., 2021).

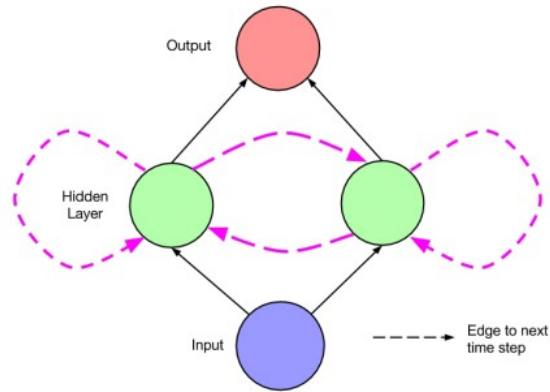
## 2.2.4 Reti Neurali Ricorrenti

Le reti neurali ricorrenti (RNN) sono reti neurali *feedforward* (Goodfellow et al., 2016), che includono la presenza di connessioni che collegano istanti temporali adiacenti. Grazie alla presenza di queste connessioni, viene introdotta nel modello la nozione di tempo. Le connessioni tra istanti temporali adiacenti, chiamate connessioni ricorrenti, possono formare cicli. Questi cicli possono essere di lunghezza unitaria quando sono connessioni sullo stesso nodo, e rappresentano la connessione con il valore del nodo a istanti di tempo adiacenti. Al tempo  $t$ , i nodi con connessioni ricorrenti ricevono come input sia il valore corrente  $x_t$  che i valori provenienti dal nodo latente  $h_{t-1}$  allo stato precedente. L'output  $\hat{y}_t$  ad ogni istante temporale  $t$  viene calcolato sulla base del valore del nodo latente  $h_t$  al tempo  $t$ . L'input  $x_{t-1}$  al tempo  $t - 1$  può influenzare l'output  $\hat{y}_t$  al tempo  $t$  e ad istanti temporali successivi per la presenza delle connessioni ricorrenti. Per specificare i passaggi necessari per il calcolo ad ogni passo in avanti di una semplice rete neurale ricorrente, come quella in Figura 4, sono necessarie due equazioni:

$$h_t = \sigma(W^{\text{hx}}x_t + W^{\text{hh}}h_{t-1} + b_h) \quad (21)$$

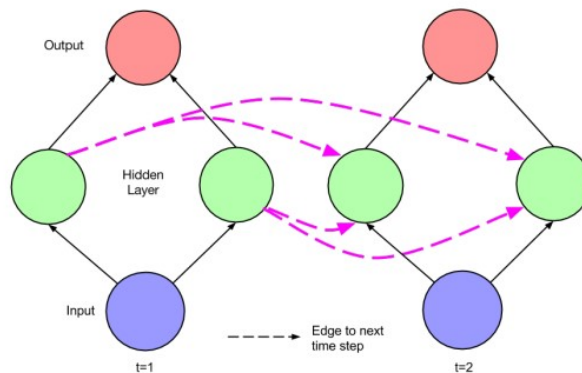
$$\hat{y}_t = W^{\text{yh}}h_t + b_y, \quad (22)$$

dove  $W^{\text{hx}}$  è la matrice dei pesi dei collegamenti tra lo strato di input e lo strato latente,  $W^{\text{hh}}$  è la matrice dei pesi dei collegamenti tra uno strato latente e se stesso all'istante temporale precedente e  $W^{\text{yh}}$  è la matrice dei pesi dei collegamenti tra lo strato latente e lo strato di output. I vettori  $b_h$  e  $b_y$  sono parametri di distorsione. La dinamica nel tempo della RNN, rappresentata in Figura 4, può essere visualizzata tramite una procedura di dispiegamento (*unfolding*), raffigurato in Figura 5. Da questa rappresentazione la rete può essere interpretata non come un ciclo ma come una rete profonda con uno strato per ogni istante temporale e pesi condivisi tra i diversi istanti temporali (Lipton et al., 2015). La RNN dispiegata può essere stimata utilizzando diversi algoritmi, tra cui una versione modificata del *backpropagation*, chiamata *backpropagation through time* (BPTT) (Werbos, 1990).



**Figura 4:** Rete neurale ricorrente semplice.

Fonte: *A Critical Review of Recurrent Neural Networks for Sequence Learning* (Lipton et al., 2015).



**Figura 5:** Rete neurale ricorrente di Figura 4 dispiegata nel tempo.

Fonte: *A Critical Review of Recurrent Neural Networks for Sequence Learning* (Lipton et al., 2015).

Esistono diverse specificazioni delle RNN. Tra le più note troviamo le reti di Jordan (Jordan, 1986) e le reti di Elman (Elman, 1990). Le reti di Jordan consistono in una rete neurale *feedforward* (FFNN) con un unico strato latente, ampliato con unità speciali. I valori dei nodi di output vengono trasmessi alle unità speciali, le quali successivamente trasmettono ai nodi dello strato latente al successivo istante temporale. Inoltre, le unità speciali nelle reti di Jordan sono connesse a se stesse. Intuitivamente, queste connessioni permettono la trasmissione di informazione attraverso diversi istanti temporali, senza perturbare l'output ad ogni istante temporale intermedio. Rispetto alla architettura introdotta da Jordan, quella


di Elman è più semplice. Ad ogni unità nello strato latente è associata una unità speciale (chiamata *context unit* dall'Autore). Ciascuna di queste unità  $m'$  prende come input l'informazione proveniente dal rispettivo nodo latente  $m$  all'istante temporale precedente, con una connessione il cui relativo peso ha valore unitario:  $w_{m'm} = 1$ . Successivamente, questo valore viene trasmesso indietro al nodo latente  $m$ , tramite una connessione standard. Tale architettura equivale ad una rete neurale ricorsiva semplice in cui ogni nodo latente ha una connessione ricorrente con se stesso. Stimando la rete con l'algoritmo di *backpropagation*, l'autore ha dimostrato che queste reti possono apprendere strutture temporali. Per quanto concerne la fase di stima di una RNN, questa può essere particolarmente impegnativa: dal punto di vista numerico, la stima di una RNN può incorrere in alcuni problemi legati all'instabilità del gradiente. Una soluzione a questo problema è rappresentata, in alcuni casi, dall'utilizzo di specifiche funzioni di attivazione e di inizializzazione dei pesi. Tra le funzioni di attivazioni preferibili da utilizzare si trovano la funzione di attivazione SELU (Klambauer et al., 2017) e la funzione di attivazione ELU (Clevert et al., 2016). In merito la funzione di inizializzazione dei pesi è consigliabile utilizzare le funzioni Glorot (Glorot e Bengio, 2010) ed He (He et al., 2015). Un'ulteriore problematica legata alle RNN è la presenza di minimi locali nella funzione di ottimizzazione, i quali possono essere un ostacolo alla fase di stima del modello. Una possibile soluzione a tale problema consiste nel ripetere la fase di stima partendo dalla specificazione di *seed* diversi per l'avvio dell'algoritmo di stima. Nonostante questo, studi recenti suggeriscono che, nella pratica, il problema ha una rilevanza minore: è stato mostrato che il rapporto tra i punti di sella e i veri minimi locali aumenta esponenzialmente con la dimensione della rete, e gli algoritmi di stima possono essere progettati per evitare i punti di sella (Dauphin et al., 2014).

### 2.2.5 Reti Neurali LSTM

Hochreiter e Schmidhuber introdussero nel 1997 l'unità *Long Short-Term Memory* (LSTM) all'interno delle RNN, con lo specifico intento di risolvere il problema dell'instabilità del gradiente (Hochreiter e Schmidhuber, 1997). Le reti LSTM assemblano una rete ricorrente standard con uno strato latente in cui ogni nodo dello strato latente è sostituito con una cella di memoria. La struttura originale della cella di memoria è rappresentata in Figura 6.



Ogni cella di memoria contiene un nodo con una connessione ricorrente su se stesso con peso unitario. In questo modo si garantisce che il gradiente possa passare attraverso diversi istanti temporali senza “scomparere” o “esplodere”.



**Figura 6:** Cella di memoria LSTM proposta da Hochreiter e Schmidhuber.

Fonte: *A Critical Review of Recurrent Neural Networks for Sequence Learning* (Lipton et al., 2015).

Il modello LSTM introduce una memoria di archiviazione intermedia attraverso la cella di memoria. Una cella di memoria è una unità composta, costruita a partire da nodi semplici connessi tramite un pattern di connessione specifico. L’innovazione consiste nell’inclusione di nodi moltiplicativi, rappresentati con il simbolo  $\Pi$ . Le componenti che costituiscono una cella di memoria sono le seguenti: nodo di input, *input gate*, stato interno, *forget gate* e *output gate*. Il nodo di input, indicato con  $g_c$ , dove  $c$  indica una cella di memoria individuale, è un nodo che viene attivato nella maniera classica dallo strato di input  $x_t$  all’istante temporale corrente, e dallo strato latente all’istante temporale precedente  $h_{t-1}$  attraverso la connessione ricorrente. Il valore dell’*input gate* è indicato con  $i_c$ . Le porte (*gates*) sono una componente distintiva delle reti LSTM. Una porta è una unità sigmoideale che viene attivata dalla osservazione corrente  $x_t$  e dallo strato latente all’istante temporale precedente  $h_{t-1}$ , come il nodo di input. Una porta viene indicata con questo nome perché il suo valore è utilizzato per moltiplicare il valore di un altro nodo. Quindi, se il suo valore è pari a zero il flusso proveniente dell’altro nodo è interrotto. Il valore dell’*input gate* moltiplica il valore del nodo di input. Nel cuore di ogni cella di memoria si trova lo stato interno: un nodo  $s_c$  con attivazione lineare. Lo

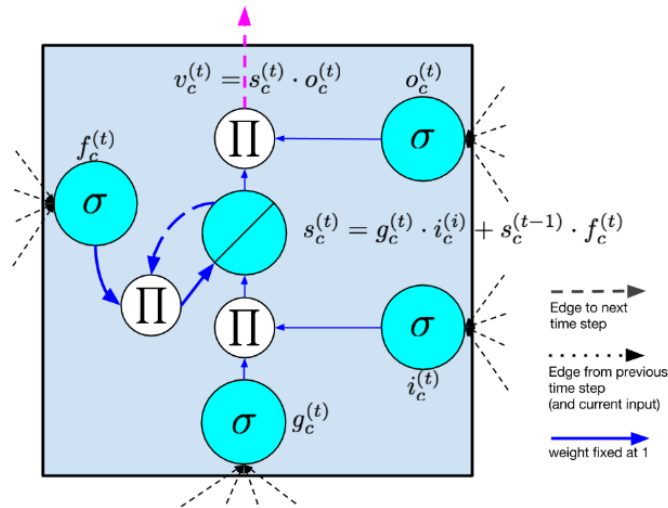
stato interno ha una connessione ricorrente su se stesso con peso unitario. Dal momento che questa connessione connette istanti temporali adiacenti con peso costante, l'errore può essere propagato attraverso gli istanti temporali senza “scompare” o “esplodere”. L'aggiornamento dello stato interno è il seguente:

$$s_{ct} = g_{ct} \odot i_{ct} + s_{ct-1}, \quad (23)$$

dove  $\odot$  indica la moltiplicazione elemento-per-elemento. Il *forget gate*, indicato con  $f_c$ , è stato introdotto successivamente (Gers et al., 2000), la sua aggiunta permette alla rete di imparare a svuotare il contenuto dello stato interno. Con il *forget gate*, l'equazione per determinare lo stato interno al passo successivo diventa:

$$s_{ct} = g_{ct} \odot i_{ct} + f_t \odot s_{ct-1}. \quad (24)$$

Il valore finale prodotto dalla cella di memoria è indicato con  $v_c$ , che corrisponde al prodotto del valore dello stato interno  $s_c$  e del valore dell'*output gate*  $o_c$ . Solitamente, il valore dello stato interno viene fatto passare attraverso una funzione di attivazione tangente iperbolica.



**Figura 7:** Cella di memoria LSTM con l'aggiunta del *forget gate* introdotto da Gers.

Fonte: *A Critical Review of Recurrent Neural Networks for Sequence Learning* (Lipton et al., 2015).

Formalmente, ad ogni istante temporale, il calcolo nelle reti LSTM con il *forget gate* segue il seguente algoritmo:

$$g_t = \phi(W^{\text{gx}}x_t + W^{\text{gh}}h_{t-1} + b_g) \quad (25)$$

$$i_t = \sigma(W^{\text{ix}}x_t + W^{\text{ih}}h_{t-1} + b_i) \quad (26)$$


$$f_t = \sigma(W^{\text{fx}}x_t + W^{\text{fh}}h_{t-1} + b_f) \quad (27)$$

$$o_t = \sigma(W^{\text{ox}}x_t + W^{\text{oh}}h_{t-1} + b_o) \quad (28)$$

$$s_t = g_t \odot i_t + f_t \odot s_{t-1} \quad (29)$$

$$h_t = \phi(s_t) \odot o_t, \quad (30)$$

dove  $\phi$  indica la funzione tangente iperbolica. Il valore dello strato latente della rete LSTM all'istante  $t$  è il vettore  $h_t$ , mentre  $h_{t-1}$  è il valore fornito da ogni cella di memoria nello strato latente all'istante precedente. La rete LSTM è in grado di imparare quando far entrare l'attivazione nello stato interno: finché l'*input gate* assume valore zero, nessuna attivazione può entrare. Allo stesso modo, impara quando far uscire il valore. Quanto entrambe le porte sono chiuse, l'attivazione rimane all'interno della cella di memoria, senza estendersi, contrarsi o influenzare l'output ad istanti temporali intermedi (Lipton et al., 2015). È stato mostrato che le reti LSTM imparano più facilmente le strutture di dipendenza temporale a lungo termine rispetto alle architetture ricorrenti classiche (Goodfellow et al., 2016).



**Figura 8:** Rete LSTM con uno strato latente composto da due celle di memoria. La rete è rappresentata nella forma dispiegata.

Fonte: *A Critical Review of Recurrent Neural Networks for Sequence Learning* (Lipton et al., 2015).

## 2.2.6 Reti Neurali GRU

La *Gated Recurrent Unit* (GRU) è una particolare architettura di rete neurale ricorrente introdotta da Cho, et al. nel 2014 (Cho et al., 2014). Il meccanismo delle unità GRU permette di imparare dipendenze di lungo termine, evitando il problema dell'instabilità del gradiente. Analogamente alla unità LSTM, la GRU ha unità di *gating* che regolano il flusso di informazione all'interno dell'unità, senza avere celle di memoria separate. Le unità GRU sono delle semplificazioni delle unità LSTM, per questa ragione hanno una architettura più semplice ed un minore numero di parametri rispetto alle LSTM. L'attivazione della  $j$ -esima unità GRU  $h_{jt}$  al tempo  $t$  corrisponde ad una interpolazione lineare tra l'attivazione precedente  $h_{jt-1}$  e l'attivazione candidata  $\tilde{h}_{jt}$ :

$$h_{jt} = (1 - z_{jt})h_{jt-1} + z_{jt}\tilde{h}_{jt}, \quad (31)$$

dove  $z_{jt}$  rappresenta una *update gate*, che decide quanto l'unità aggiorna la sua attivazione. L'*update gate* è determinato nel modo seguente:

$$z_{jt} = \sigma(W^{zx}x_t + W^{zh}h_{t-1})_j, \quad (32)$$


dove  $\sigma$  è la funzione sigmoidale logistica. L'attivazione candidata  $\tilde{h}_{jt}$  viene calcolata in maniera simile a quella delle unità ricorrenti tradizionali:

$$\tilde{h}_{jt} = \tanh(W^{hx}x_t + W^{hh}(r_t \odot h_{t-1}))_j, \quad (33)$$

dove  $r_t$  indica il *reset gate*. Il *reset gate* controlla sia il *forget gate* che l'*input gate*: quando è spento, e quindi  $r_{jt}$  è vicino a zero, il *forget gate* è chiuso e l'*input gate* è aperto. Se è aperto, e quindi  $r_{jt}$  è prossimo ad uno, accade il contrario. In altri termini, quando è necessario memorizzare una nuova informazione, lo spazio di memorizzazione viene liberato dalla informazione memorizzata allo stato precedente. Il *reset gate*  $r_{jt}$  viene calcolato nella maniera seguente:

$$r_{jt} = \sigma(W^{rx}x_t + W_r^{rh}h_{t-1}). \quad (34)$$

Per quanto concerne la comparazione tra reti con unità LSTM e reti con unità GRU, un confronto empirico ha condotto alla conclusione che le performance delle due strutture sono comparabili (Chung et al., 2014).



**Figura 9:** Architettura di un'unità GRU.

Fonte: *Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling* (Chung et al., 2014).

## 2.3 Metriche per il Confronto

Al fine di determinare e confrontare l'accuratezza dei diversi modelli è necessario stabilire alcune misure che sintetizzino la distribuzione dell'errore. Comunemente una misura d'errore si calcola determinando una funzione di perdita che viene successivamente aggregata tramite una media. Esistono diverse misure d'accuratezza utilizzate nell'ambito della previsione, in questa analisi si è scelto di valutare i modelli sulla base di: l'errore assoluto medio (MAE), la radice dell'errore quadratico medio (RMSE) e l'errore assoluto medio percentuale (MAPE). Durante la prima fase dell'analisi queste quantità vengono determinate sul *testing set*, ovvero su quelle osservazioni appartenenti all'intervallo temporale 1 luglio 2022 - 31 gennaio 2022, che non sono state utilizzate per la stima dei modelli. Durante la seconda fase, i modelli saranno valutati esclusivamente in termini di MAPE, in modo tale da poter confrontare i risultati ottenuti nelle due fasi dell'analisi. Infine, l'RMSE viene anche utilizzato in fase di convalida incrociata per determinare il valore ottimale degli iperparametri per i modelli Prophet, NeuralProphet, RNN, LSTM e GRU. In Tabella 1 vengono riportate le definizioni teoriche delle metriche scelte.

**Tabella 1:** Metriche scelte per la valutazione dei modelli.

---

Metrica	Definizione teorica
MAE	$\frac{1}{n} \sum_{t=1}^n  y_t - \hat{y}_t $
RMSE	$\sqrt{\frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2}$
MAPE	$\frac{1}{n} \sum_{t=1}^n 100 \left  \frac{y_t - \hat{y}_t}{y_t} \right $

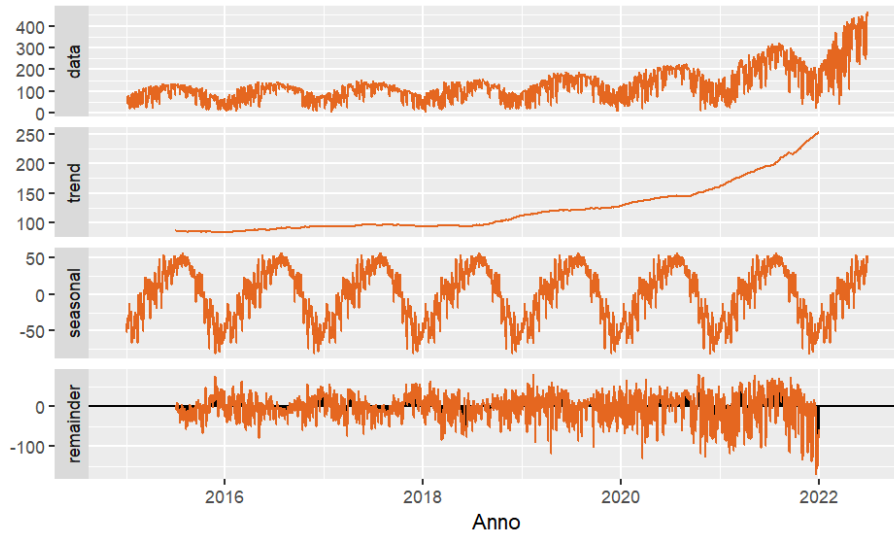
---



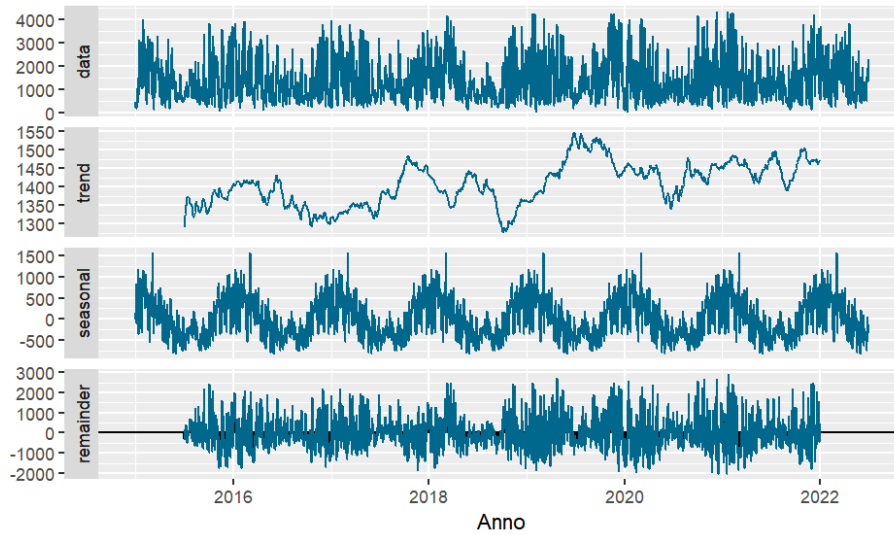
### 3. Analisi Empiriche

Inizialmente, è essenziale condurre un'analisi descrittiva delle serie temporali relative alla potenza di produzione energetica. Figura 10 e Figura 11 presentano rispettivamente le decomposizioni in trend e stagionalità delle serie temporali riguardanti la potenza di produzione di energia solare ed eolica. In Figura A9 e Figura A10 sono inoltre rappresentate le funzioni di autocorrelazione (ACF) e di autocorrelazione parziale (PACF) delle serie in analisi. Un'osservazione iniziale evidenzia un chiaro trend crescente nella serie della potenza di produzione di energia solare, mentre in entrambe le serie è rilevante la presenza di una componente stagionale annuale. Da queste analisi grafiche emergono due importanti conclusioni: la serie della produzione di energia solare si configura come non stazionaria, mentre quella relativa alla produzione di energia eolica suggerisce una probabile stazionarietà. Tali conclusioni trovano conferma attraverso il test Augmented di Dickey–Fuller (ADF) (Dickey e Fuller, 1979), il quale stabilisce che la serie della potenza di produzione di energia solare è non stazionaria, mentre la serie relativa alla potenza di produzione di energia eolica risulta stazionaria, mantenendo un livello di significatività pari a 0.05.





**Figura 10:** Scomposizione della serie della potenza di produzione di energia solare, 1 gennaio 2015 - 30 giugno 2022.




**Figura 11:** Scomposizione della serie della potenza di produzione di energia eolica, 1 gennaio 2015 - 30 giugno 2022.

## 3.1 Risultati per il Modello di Regressione con Errori ARMA


La stima del modello di regressione con errori ARMA per la serie storica della potenza di produzione di energia solare prevede in primo luogo la specificazione della matrice di regressione contenente le variabili esogene. Come detto in precedenza, le variabili che sono ritenute d'interesse per spiegare la potenza con cui viene prodotta energia solare sono: la temperatura, la copertura nuvolosa, l'irradiazione solare e la capacità totale installata degli impianti solari. La matrice finale è quindi composta da 28 colonne e 2738 righe, in quanto ognuna delle variabili meteorologiche è stata misurata per ciascuna delle nove città portoghesi prese in considerazione. Poiché in letteratura, così come nella definizione del modello, non sono state riportate indicazioni su come la normalizzazione dei dati influisca sulla accuratezza del modello di regressione con errori ARMA, quest'ultimo è stato stimato sia sulle serie normalizzate, sia sulle serie non normalizzate. Dal momento che è stato osservato un lieve peggioramento delle prestazioni del modello stimato sulle serie normalizzate rispetto al modello stimato con i dati non normalizzati, è stato deciso di non applicare tale trasformazione ai dati. Per la selezione del modello è stata eseguita una procedura *stepwise* basata sul criterio di informazione di Akaike (AIC) (Akaike, 1998). Il modello finale identifica per gli errori un modello ARMA(2,2) con AIC pari a 23380.75, i cui coefficienti sono raccolti in Tabella A1. Per analizzare la bontà di adattamento del modello si esegue l'analisi dei residui. Dall'analisi della ACF e della PACF, rappresentate in Figura 12, emerge che sono presenti diversi valori del *lag* per cui la ACF e la PACF sono significativamente diverse da zero, fissato un livello di significatività pari a 0.05. Questo indica che è presente una struttura di correlazione seriale nei residui e che quindi il modello non riesce a cogliere a pieno la variabilità temporale del fenomeno in analisi. Circa l'analisi dell'accuratezza delle previsioni, in Tabella 4 (Sezione 3.7) sono riportati i valori del MAE, dell'RMSE e del MAPE per le previsioni sull'intero *testing set*. Inoltre, in Tabella 5 (Sezione 3.7) vengono mostrati i risultati del MAPE calcolato separatamente per ciascun mese del *testing set*. Per il caso in analisi si nota che l'accuratezza diminuisce all'aumentare della distanza temporale tra gli istanti temporali delle previsioni e quelli relativi all'insieme di dati utilizzati per la stima del modello. Infine,

il confronto grafico tra le previsioni ottenute e i valori osservati può essere svolto tramite Figura A11.



**Figura 12:** (a): ACF dei residui del modello di regressione con errori ARMA per la potenza della produzione di energia solare. (b): PACF dei residui del modello di regressione con errori ARMA per la potenza della produzione di energia solare.

Con lo stesso procedimento viene stimato il modello di regressione con errori ARMA per la serie temporale della potenza di produzione di energia eolica. La matrice di regressione comprende le variabili esogene temperatura, velocità del vento a 100 metri dal suolo, pressione atmosferica a livello del mare e capacità totale installata degli impianti eolici. Anche in questo caso la matrice di regressione è composta da 28 colonne e 2738 righe. Dopo aver constatato che l'applicazione della normalizzazione ai dati ha portato ad una diminuzione dell'accuratezza del modello rispetto all'utilizzo dati non normalizzati, è stato deciso di non effettuare questa trasformazione sulle serie. Successivamente è stata svolta la procedura di selezione *stepwise* del modello basata sull'AIC, la quale porta ad identificare per la serie degli errori un modello ARMA(2,1), con AIC pari a 37412.97. I coefficienti di tale modello sono raccolti in Tabella A2. Si procede in seguito con l'analisi dei residui, in Figura 13 sono rappresentate la ACF e la PACF della serie dei residui del modello analizzato. Dai grafici si evince che solo per un numero ristretto di *lag* i valori della ACF e della PACF sono significativamente diversi da zero, considerando un livello di significatività fissato pari a 0.05. Ciò indica che il modello è in grado di cogliere la struttura temporale della serie della potenza di produzione di energia eolica in modo soddisfacente.



**Figura 13:** (a): ACF dei residui del modello di regressione con errori ARMA per la potenza della produzione di energia eolica. (b): PACF dei residui del modello di regressione con errori ARMA per la potenza della produzione di energia eolica.


In Tabella 6 (Sezione 3.7) sono riportati i valori del MAE, dell’RMSE e del MAPE sull’intero *testing set* mentre in Tabella 7 (Sezione 3.7) si trovano i valori del MAPE determinati separatamente per ciascun mese. In questo caso, si evince dalle metriche che l’accuratezza del modello non assume un andamento specifico al variare dei mesi. In Figura A16 sono rappresentate la serie prevista dal modello in analisi e la serie osservata, dalla quale si nota una buona capacità predittiva del modello.

## 3.2 Risultati per il Modello Prophet

Il modello Prophet richiede inizialmente la specificazione della struttura delle componenti trend, stagionalità e festività e delle variabili esogene. Per quanto concerne la struttura delle componenti è stato scelto il trend con crescita lineare a tratti, la stagionalità di tipo additivo e l’assenza della componente festività. Il modello Prophet, nella sua specificazione di base, e quindi per come è stato principalmente utilizzato, opera una standardizzazione sia della serie d’interesse sia delle variabili esogene. Al fine di ottenere un migliore adattamento ai dati, è stata svolta una fase di regolarizzazione degli iperparametri, che viene eseguita tramite una procedura di convalida incrociata basata sulla minimizzazione dell’RMSE. Gli iperparametri che vengono ottimizzati sono *seasonality.prior.scale* e *changepoint.prior.scale*, i quali regola-

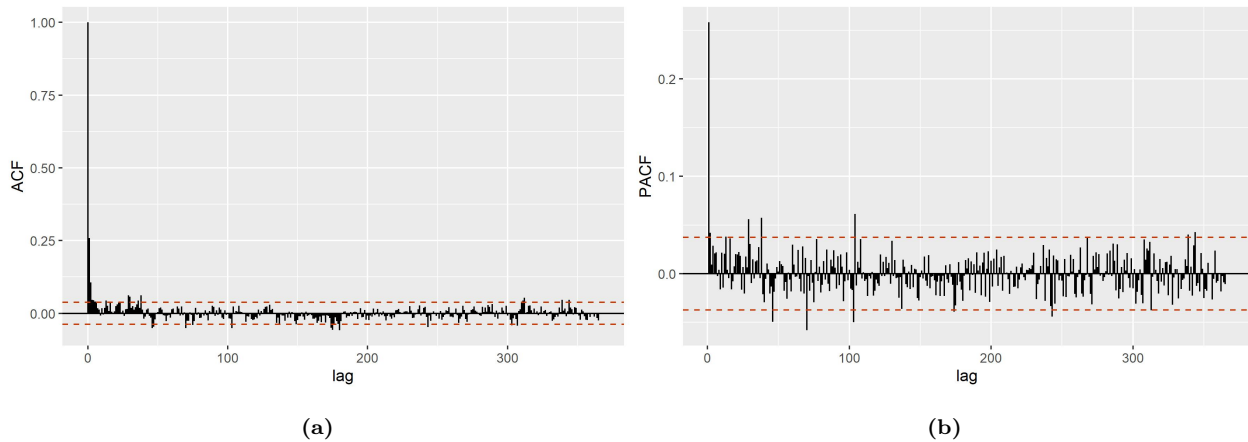
no rispettivamente la forza della componente stagionale e la quantità di *change point*, ossia la flessibilità della componente trend. Questi due iperparametri corrispondono rispettivamente al parametro  $\sigma^2$  della distribuzione a priori di  $\beta$  in Equazione 9, e al parametro  $\tau$  della distribuzione a priori di  $\delta_j$  in Equazione 8. Per lo svolgimento della convalida incrociata è necessario stabilire delle porzioni di serie appartenenti al *training set* adibite a *validation set*. Nello specifico vengono selezionati cinque intervalli di lunghezza pari a 230 osservazioni, distribuiti uniformemente tra maggio 2020 e giugno 2022, per i quali viene determinato il valore dell'RMSE relativo al modello stimato con tutti i dati precedenti all'inizio dell'intervallo stesso.

Per quanto riguarda la serie temporale della potenza di produzione di energia solare, oltre ad aggiungere come variabili esogene d'interesse le variabili meteorologiche e la capacità installata degli impianti solari, si è scelto di includere anche i valori ritardati della serie stessa. Nello specifico vengono incluse trenta nuove serie che corrispondono alle serie ritardate con un *lag* da 1 a 30. Per il modello così specificato, la procedura di convalida incrociata porta alla selezione dei valori 1 e 0.001 rispettivamente per gli iperparametri *seasonality.prior.scale* e *changeoint.prior.scale*. I coefficienti di tale modello sono rappresentati in Tabella A3. Una volta stimato il modello con gli iperparametri ottimi, si analizzano i residui e la loro struttura di dipendenza temporale al fine di valutare la bontà di adattamento. In Figura 14 sono rappresentate la ACF e la PACF dei residui del modello in analisi, dalle quali è chiaramente visibile la forte presenza di una struttura di dipendenza temporale nella serie dei residui. I risultati delle metriche di accuratezza sono riportati in Tabella 4 e in Tabella 5. Si nota che il modello Prophet ha prestazioni complessivamente migliori rispetto al modello di regressione con errori ARMA quando valutato sull'intero *testing set*, e come esso produce previsioni sempre meno accurate mano mano che ci si allontana dai dati utilizzati per la stima del modello. Infine, in Figura A12 sono rappresentate la serie prevista e quella osservata, al fine di valutare anche graficamente l'accuratezza delle previsioni.



**Figura 14:** (a): ACF dei residui del modello Prophet per la potenza della produzione di energia solare. (b): PACF dei residui del modello Prophet per la potenza della produzione di energia solare.

Per quanto concerne la serie temporale della potenza di produzione di energia eolica, dopo la specificazione dei regressori d'interesse, i quali includono le variabili meteorologiche, la capacità installata e i valori della serie stessa ritardata con *lag* da 1 a 30, si esegue la procedura di convalida incrociata per ottimizzare gli iperparametri come descritto in precedenza. I valori ottimali per gli iperparametri *seasonality.prior.scale* e *changepoint.prior.scale* risultano essere rispettivamente 15 e 0.01. I coefficienti di tale modello sono rappresentati in Tabella A4. In merito all'analisi della bontà di adattamento del modello, in Figura 15 sono rappresentate la ACF e la PACF dei residui. Dai grafici è possibile notare che solo per pochi *lag* i valori della ACF e della PACF non sono significativamente diversi da zero, indicando un adattamento ai dati complessivamente soddisfacente. In riferimento all'accuratezza delle previsioni prodotte, in Tabella 6 sono riportati i valori delle tre metriche scelte sull'intero *testing set*. In termini di MAE e di RMSE il modello Prophet risulta avere previsioni maggiormente accurate rispetto al modello di regressione con errori ARMA, mentre in termini di MAPE il modello Prophet risulta fornire delle previsioni meno accurate. Da Tabella 7, si evince inoltre che il modello Prophet non presenta un andamento specifico nell'accuratezza delle previsioni al variare dei sei mesi del *testing set*. In aggiunta, tramite Figura A17 è possibile confrontare graficamente i valori predetti con quelli osservati.




**Figura 15:** (a): ACF dei residui del modello Prophet per la potenza della produzione di energia eolica. (b): PACF dei residui del modello Prophet per la potenza della produzione di energia eolica.

### 3.3 Risultati per il modello NeuarlProphet

Nella configurazione di base del modello NeuralProphet la procedura di stima non richiede una fase di regolazione degli iperparametri manuale: tale modello infatti svolge una procedura di ottimizzazione automatica. Inoltre, il modello opera una *soft normalization* della serie oggetto di studio, ossia una normalizzazione che scala i valori della serie tra il valore minimo e il novantacinquesimo percentile della distribuzione dei dati, ed una standardizzazione delle variabili esogene. Relativamente a tali variabili, oltre alle variabili esogene legate alle condizioni meteorologiche e alla capacità installata, è stato scelto di incorporare anche i valori ritardati della serie stessa. Nello specifico vengono inclusi i primi trenta ritardi come fatto per il modello Prophet.

Circa la serie della potenza di produzione di energia solare, il modello seleziona per gli iperparametri *batch size* e *epochs* i valori 32 e 145 rispettivamente. Tramite l'analisi dei residui si evince che il modello stimato è in grado di cogliere parzialmente la struttura di dipendenza temporale della serie in analisi. Da Figura 16, che rappresenta la ACF e la PACF dei residui del modello, si nota infatti la presenza di una debole struttura di autocorrelazione in tale serie. In Tabella 4 sono riportati valori delle metriche di valutazione sull'intero *testing set*, dalla quale è possibile notare che il modello in analisi produce previsioni maggiormente accurate rispetto al modello di regressione con errori ARMA e al modello Prophet. Inoltre, da Tabella

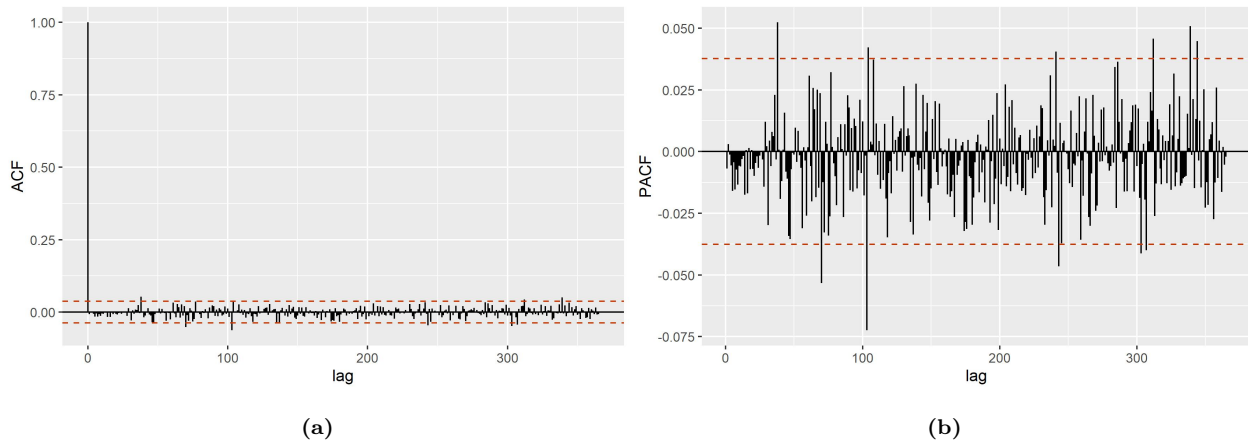
5 si evince che il modello fornisce previsioni la cui accuratezza diminuisce all'aumentare della distanza rispetto ai dati di stima, come per il modello di regressione con errori ARMA e il modello Prophet. Infine, tramite Figura A13 è possibile valutare graficamente l'accuratezza delle previsioni del modello in analisi.



**Figura 16:** (a): ACF dei residui del modello NeuarlProphet per la potenza della produzione di energia solare. (b): PACF dei residui del modello NeuarlProphet per la potenza della produzione di energia solare.

Per quanto riguarda la serie temporale della potenza di produzione di energia eolica, il modello NeuarlProphet seleziona per gli iperparametri *batch size* e *epochs* i valori 32 e 145 rispettivamente, come per la serie della potenza di produzione di energia solare. Il modello mostra un adattamento ai dati soddisfacente: in Figura 17 sono rappresentate la ACF e la PACF della serie dei residui, da cui è infatti possibile notare che non è presente una evidente struttura di dipendenza temporale nella serie in analisi. I valori delle metriche di valutazione sull'intero *testing set* sono riportate in Tabella 6. Il modello NeuarlProphet risulta avere migliore capacità predittiva rispetto al modello di regressione con errori ARMA e al modello Prophet solamente in termini di MAE, mentre in termini di RMSE e MAPE risulta avere inferiore capacità predittiva. Da Tabella 7 si nota nuovamente che la capacità predittiva del modello NeuralProphet non ha uno specifico andamento al seguirsi dei mesi. In conclusione, in Figura A18 sono rappresentate la serie delle previsioni e quella dei valori osservati.






**Figura 17:** (a): ACF dei residui del modello NeuarlProphet per la potenza della produzione di energia eolica. (b): PACF dei residui del modello NeuarlProphet per la potenza della produzione di energia eolica.

### 3.4 Risultati per il Modello RNN

Di seguito vengono fornite alcune indicazioni fondamentali sulla costruzione e sulla fase di stima delle reti neurali RNN, LSTM e GRU. In primo luogo, è necessario operare una normalizzazione dei dati, questo viene fatto per ridurre gli errori di stima e diminuire il tempo necessario alla fase di stima della rete neurale (Sola e Sevilla, 1997). Di conseguenza, sia le serie di *training* relative alla potenza di produzione, sia quelle relative alle variabili esplicative, vengono normalizzate. Le serie di *testing* vengono normalizzate secondo i rispettivi valori minimi e massimi nelle serie di *training*. Per la selezione degli iperparametri viene eseguita una procedura di convalida incrociata basata sulla minimizzazione dell'RMSE. Gli iperparametri che vengono ottimizzati sono: *batch size*, *epochs*, *learning rate*, *dropout rate*, funzione di attivazione, numero di nodi per strato e numero di strati. Sia in fase di convalida incrociata che durante la stima del modello finale, la procedura di ottimizzazione dei parametri viene eseguita tramite l'utilizzo dell'algoritmo *Adam*. L'ottimizzazione *Adam* è un metodo di discesa del gradiente stocastico che si basa sulla stima adattiva dei momenti di primo e secondo ordine (Kingma e Ba, 2017). La struttura della convalida incrociata è stata costruita nella maniera seguente: l'intero *training set* è stato diviso in modo tale da ottenere i tipici *fold* della procedura. Dalla divisione del *training set* sono state ottenute cinque porzioni di serie che mantengono l'ordinamento temporale dei dati. Ciascuna porzione di serie inizia con

la prima osservazione, ossia quella relativa al 1 gennaio 2015, e le cinque serie comprendono l'80%, 85%, 90%, 95% e 100% della serie che costituisce il *training set*. Ciascuna di esse viene successivamente divisa in maniera tale da ottenere un *training set* e un *validation set* per la convalida incrociata. Nello specifico, il *training set* per la convalida incrociata è costituito dal primo 90% di ogni porzione e il *validation set* è costituito dal rimanente 10%. La procedura di divisione è stata eseguita in maniera tale da mantenere sempre l'ordinamento temporale dei dati. In Figura 18 è rappresentata graficamente la procedura di divisione del *training set* per la convalida incrociata.



**Figura 18:** Divisione del *training set* per la procedura di convalida incrociata per i modelli RNN, LSTM e GRU.


A causa della elevata numerosità degli iperparametri da ottimizzare, è stato scelto di operare una ricerca che esplora un sottoinsieme casuale dello spazio degli iperparametri, a partire da uno spazio precedentemente specificato. Il numero di diverse combinazioni da testare è stato fissato pari a 500, in modo tale da ridurre il tempo computazionale necessario alla selezione degli iperparametri. Rispetto al metodo classico, che esplora tutte le combinazioni possibili di iperparametri, rende la procedura più efficiente in termini di tempo e risorse, limitando allo stesso tempo l'ottimizzazione degli iperparametri. Nell'ambito dell'inizializzazione dei pesi, è stata adottata l'inizializzazione Glorot uniforme. Questa metodologia è specificamente progettata per ridurre il rischio di instabilità del gradiente. L'obiettivo principale dell'inizializzazione Glorot uniforme è mantenere approssimativamente costante la varianza degli output dei nodi attraverso i vari strati della rete. Ciò mira a prevenire sia la possibile riduzione eccessiva dei gradienti ("scomparsa" del gradiente), sia l'eventuale amplificazione ("esplosione" del gradiente) durante il processo di stima.

Per quanto concerne la RNN per la potenza della produzione di energia solare, la struttura che risulta avere il minor valore di RMSE sul *testing set* è quella composta da un unico strato ricorrente. In Tabella 2 sono riportati i valori ottimali degli iperparametri selezionati tramite procedura di convalida incrociata.

**Tabella 2:** Valori ottimali degli iperparametri dei modelli RNN, LSTM e GRU per la potenza di produzione di energia solare.

	RNN	LSTM	GRU
Batch size	100	500	100
Epochs	200	200	100
Learning rate	0.01	0.01	0.005
Dropout rate	0	0	0
Funzione di attivazione	ELU	RELU	Lineare
Numero di nodi	10	10	20
Numero di strati	1	1	1

In merito alla bontà di adattamento del modello, in Figura 19 sono rappresentate la ACF e la PACF dei residui del modello specificato, dalle quali è possibile notare che i residui presentano una sostanziale dipendenza temporale. Ciò indica che il modello non riesce a cogliere a pieno la struttura temporale della serie in analisi. In Tabella 4 sono riportati i risultati relativi alle previsioni sull'intero *testing set*: il modello RNN risulta avere migliore capacità predittiva rispetto al modello di regressione con errori ARMA, Prophet e NeuralProphet. Da Tabella 5 si evince inoltre che, come per i modelli precedenti, la capacità predittiva diminuisce all'aumentare della distanza rispetto ai dati su cui è stato stimato il modello. È possibile infine confrontare le previsioni con i dati osservati tramite Figura 26.



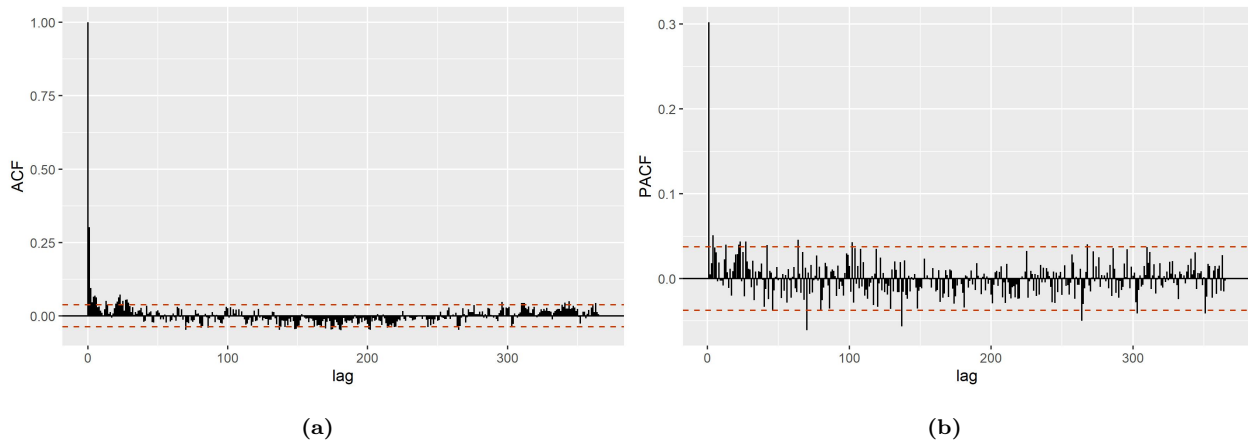
**Figura 19:** (a): ACF dei residui del modello RNN per la potenza della produzione di energia solare. (b): PACF dei residui del modello RNN per la potenza della produzione di energia solare.

In riferimento alla serie della potenza di produzione di energia eolica, la struttura finale della RNN è composta da un unico strato ricorrente. In Tabella 3 sono riportati i risultati ottenuti dalla procedura di convalida incrociata per la RNN relativa alla serie in analisi.

**Tabella 3:** Valori ottimali degli iperparametri del modello RNN per la potenza di produzione di energia eolica.

	RNN	LSTM	GRU
Batch size	100	500	100
Epochs	200	200	100
Learning rate	0.001	0.005	0.005
Dropout rate	0	0	0
Funzione di attivazione	RELU	Tangente iperbolica	Lineare
Numero di nodi	20	10	20
Numero di strati	1	3	2

Dal grafico della ACF e della PACF dei residui del modello stimato con gli iperparametri ottimali, rappresentate in Figura 20, emerge che il modello presenta un adattamento complessivamente soddisfacente ai dati. Ciò è evidenziato dal fatto che per un numero limitato di *lag*, i valori della ACF e della PACF si discostano in maniera significativa dallo zero.



**Figura 20:** (a): ACF dei residui del modello RNN per la potenza della produzione di energia eolica. (b): PACF dei residui del modello RNN per la potenza della produzione di energia eolica.


Riguardo la capacità predittiva del modello, i valori delle metriche determinate sul *testing set* sono raccolte in Tabella 6. Da tale tabella si nota che in termini MAE la RNN risulta avere minore capacità predittiva rispetto al modello NeuralProphet, in termini di RMSE risulta essere il migliore modello finora stimato e in termini di MAPE risulta peggiore rispetto al modello di regressione con errori ARMA e al modello Prophet. Analizzando la capacità predittiva al variare dei mesi, si nota da Tabella 7 che il modello non presenta un andamento specifico nell'accuratezza al susseguirsi dei mesi, come fin qui osservato per i modelli per la serie della potenza di produzione di energia eolica. Infine, tramite Figura A19 è possibile confrontare graficamente la serie delle previsioni con la serie dei dati osservati.

### 3.5 Risultati per il Modello LSTM

Si passa successivamente alla stima del modello LSTM, per il quale viene seguita la procedura di stima delle reti neurali descritta in precedenza.

Circa la serie della potenza di produzione di energia solare, in Tabella 2 sono riportati i valori ottimali degli iperparametri. Il modello finale è quindi composto da un unico strato che presenta le tipiche celle di memoria del modello in analisi. La stima del modello così specificato risulta avere un adattamento ai dati non del tutto soddisfacente: in Figura 21 sono rappresentate le funzioni ACF e PACF dei residui del modello, dalle quali è possibile

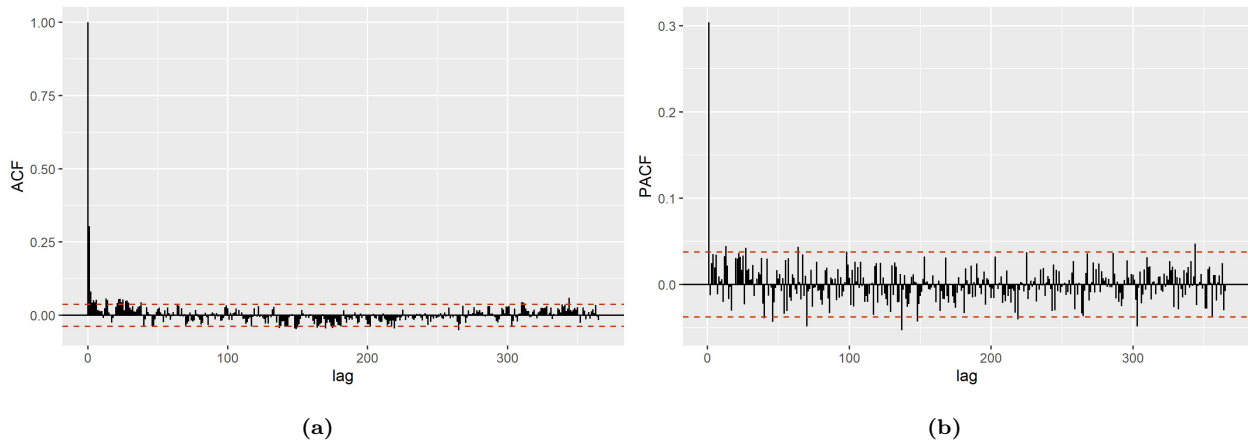
notare la presenza di una struttura di dipendenza temporale in tale serie.



**Figura 21:** (a): ACF dei residui del modello LSTM per la potenza della produzione di energia solare. (b): PACF dei residui del modello LSTM per la potenza della produzione di energia solare.

Relativamente alla valutazione dell'accuratezza predittiva del modello LSTM per la potenza di produzione di energia solare, in Tabella 4 sono riportati i valori delle metriche scelte. Il modello risulta avere minore capacità predittiva solamente rispetto al modello RNN sia in termini di MAE, che RMSE e MAPE. Inoltre, da Tabella 5 è possibile notare che anche per il modello LSTM la capacità predittiva diminuisce all'aumentare della distanza dai dati su cui è stato stimato il modello. In aggiunta, tramite Figura A14 è possibile valutare graficamente l'accuratezza delle previsioni ottenute dal modello in analisi.

Per quanto concerne la rete LSTM per la potenza di produzione di energia eolica, la procedura di convalida incrociata porta alla selezione di una rete con tre strati latenti che presentano celle di memoria LSTM. Gli ulteriori valori degli iperparametri ottimizzati sono riportati in Tabella 3. Riguardo la bontà di adattamento del modello, in Figura 22 sono riportate la ACF e la PACF dei residui. Dai grafici si nota che, come per il modello RNN, solo per un numero ristretto di valori del  $lag$  il valore delle due funzioni è significativamente diverso da zero. Questo indica che il modello coglie in maniera soddisfacente la struttura temporale dei dati.




**Figura 22:** (a): ACF dei residui del modello LSTM per la potenza della produzione di energia eolica. (b): PACF dei residui del modello LSTM per la potenza della produzione di energia eolica.

Relativamente all'accuratezza delle previsioni sul *testing set*, i valori delle tre metriche scelte sono riportati in Tabella 6. La rete LSTM risulta avere la miglior capacità predittiva tra i modelli finora analizzati rispetto alle tre metriche scelte per la valutazione. In aggiunta, persiste l'osservazione effettuata precedentemente per i modelli di previsione per la serie della potenza di produzione di energia eolica, in cui la capacità predittiva non mostra un andamento specifico al variare dei mesi, come evidenziato da Tabella 7. Infine, è possibile operare un confronto grafico tra la serie delle previsioni e quella dei dati osservati tramite Figura 28.

### 3.6 Risultati per il Modello GRU

L'ultimo modello che viene stimato e valutato è il modello GRU, per il quale valgono le considerazioni fatte in precedenza, relativamente alla procedura di stima delle reti neurali.

Per la serie della potenza di produzione di energia solare la procedura di convalida incrociata porta alla selezione di una rete con un unico strato latente che presenta unità GRU. In Tabella 2 sono riportati i valori selezionati per gli ulteriori iperparametri. Il modello così specificato risulta avere un adattamento ai dati non soddisfacente. Come evidenzia Figura 23, che rappresenta le funzioni ACF e PACF dei residui del modello, è presente una forte struttura di dipendenza temporale in tale serie.




**Figura 23:** (a): ACF dei residui del modello GRU per la potenza della produzione di energia solare. (b): PACF dei residui del modello GRU per la potenza della produzione di energia solare.

In riferimento alla capacità predittiva del modello, in Tabella 4 sono riportati i valori delle metriche scelte per li confronto. Il modello GRU ha capacità predittiva simile a quella delle altre reti neurali: risulta avere minore capacità predittiva rispetto ai modelli RNN e LSTM in termini di MAE e MAPE, mentre in termini di RMSE risulta essere migliore rispetto al modello LSTM. Inoltre, ancora una volta, come si evince da Tabella 5 il modello ha capacità predittiva decrescente all’aumentare della distanza dai dati su cui è stato stimato. Infine, la valutazione grafica dell’accuratezza delle previsioni può essere svolta tramite Figura A15.

Per quanto riguarda la serie della potenza di produzione di energia eolica, la procedura di convalida incrociata, porta alla selezione dei valori ottimali per gli iperparametri d’interesse riportati in Tabella 3. La struttura finale presenta due strati latenti con unità GRU. Tale modello risulta essere in grado di cogliere la struttura temporale dei dati: da Figura 24, che rappresenta la ACF e la PACF dei residui, si evince infatti che i valori della ACF e della PACF sono prevalentemente diversi da zero. Relativamente all’analisi della capacità predittiva del modello, da Tabella 6, che riporta i valori delle metriche scelte sull’intero *testing set*, si conclude che il modello GRU risulta essere il migliore modello in termini di MAPE, in termini di MAE risulta essere peggiore rispetto al modello LSTM e al modello NeuralProphet, mentre in termini di RMSE risulta essere migliore al modello di regressione con errori ARMA e al modello NeuralProphet. Inoltre, secondo Tabella 7, il modello non presenta un andamento specifico nella capacità predittiva al seguirsi dei mesi, come osservato



per tutti i modelli analizzati. In aggiunta, il confronto grafico tra la serie delle previsioni e la serie dei valori osservati può essere svolto tramite Figura A20.




**Figura 24:** (a): ACF dei residui del modello GRU per la potenza della produzione di energia eolica. (b): PACF dei residui del modello GRU per la potenza della produzione di energia eolica.

### 3.7 Analisi Comparativa dei Risultati

La sezione corrente è dedicata ai confronti finali, con l'obiettivo di identificare il modello con la maggiore capacità predittiva sul *testing set*. La fase successiva dell'analisi affronta infatti l'esplorazione dei risultati ottenuti dai vari modelli stimati nel corso di questa ricerca.

In merito alla serie della potenza di produzione di energia solare, come precedentemente indicato, Tabella 4 e Tabella 5 forniscono una panoramica dei risultati relativi all'analisi dei vari modelli. In generale, emerge una netta superiorità in termini di capacità predittiva delle reti neurali rispetto al modello di regressione con errori ARMA, Prophet e NeuralProphet. Un'analisi più approfondita delle metriche e dei singoli modelli rivela che il modello RNN dimostra la capacità predittiva più elevata su l'intero *testing set*. Di conseguenza, basandoci sui dati presenti nella Tabella 4, il modello RNN emerge come la scelta migliore, presentando un MAE pari a 25.18, un RMSE pari a 31.86 e un MAPE pari a 11.23. In Figura 25 viene rappresentata graficamente la struttura del modello selezionato. Un'osservazione rilevante riguarda la capacità predittiva dei modelli al variare dei mesi del *testing set*. Come ci si

potrebbe aspettare, tutti i modelli mostrano una tendenza a fornire previsioni meno accurate man mano che ci si allontana dalle osservazioni utilizzate per la stima dei modelli.



**Figura 25:** Rappresentazione grafica della struttura del modello RNN selezionato per la previsione delle potenze di produzione di energia solare, dove  $x_i$  indica i nodi di input,  $r_i$  indica i nodi dello strato ricorrente,  $d_i$  rappresenta i nodi degli strati densi e  $y_1$  costituisce il nodo di output.

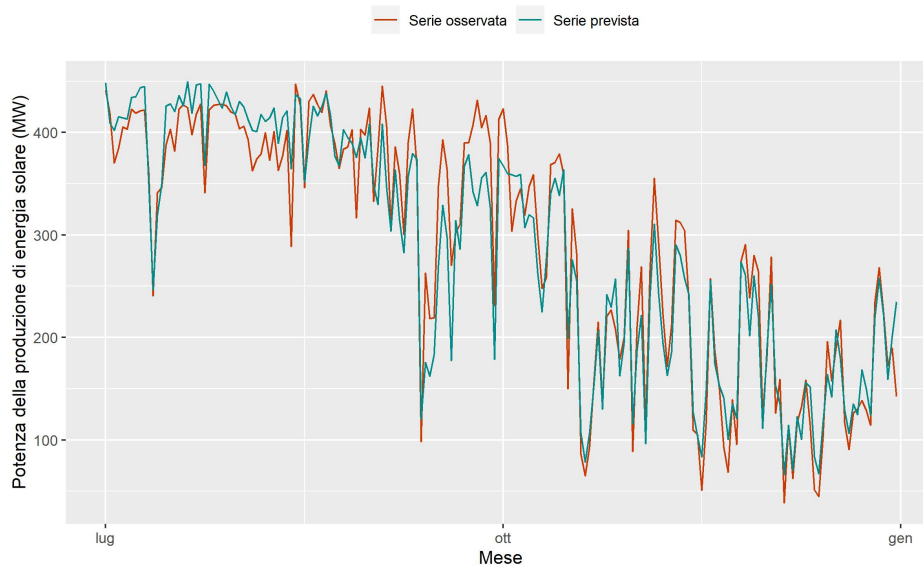
**Tabella 4:** Metriche per la valutazione dell'accuratezza dei modelli per la potenza di produzione di energia solare. MAE, RMSE e MAPE determinati sull'intero *testing set* ( $MAE$ ,  $RMSE$ ,  $MAPE$ ).

Modello	$MAE$	$RMSE$	$MAPE$
Regresione con errori ARMA	63.56	85.42	48.26
Prophet	52.48	67.87	38.06
NeuarlProphet	44.88	53.60	23.32
RNN	<b>25.18</b>	<b>31.86</b>	<b>11.23</b>
LSTM	26.06	32.00	11.67
GRU	26.36	31.99	13.03

**Tabella 5:** MAPE calcolato al variare di ogni mese del *testing set* per ciascun modello stimato per la potenza di produzione di energia solare ( $MAPE^L$ : MAPE relativo al mese di luglio,  $MAPE^A$ : MAPE relativo al mese di agosto,  $MAPE^S$ : MAPE relativo al mese di settembre,  $MAPE^O$ : MAPE relativo al mese di ottobre,  $MAPE^N$ : MAPE relativo al mese di novembre,  $MAPE^D$ : MAPE relativo al mese di dicembre).


Modello	$MAPE^L$	$MAPE^A$	$MAPE^S$	$MAPE^O$	$MAPE^N$	$MAPE^D$
Regressione con errori ARMA	4.68	5.83	16.14	50.77	79.48	132.61
Prophet	7.15	7.09	16.86	45.95	59.31	91.99
NeuarlProphet	6.64	9.90	17.87	33.27	31.47	40.87
RNN	<b>4.25</b>	5.82	13.72	10.79	15.17	<b>17.85</b>
LSTM	8.29	7.16	<b>10.55</b>	<b>10.77</b>	<b>13.72</b>	19.56
GRU	7.21	<b>5.57</b>	10.81	12.94	16.21	24.47

In Figura 26 sono illustrate le previsioni generate dal modello RNN e i dati osservati della serie temporale della potenza di produzione di energia solare, per il periodo compreso tra il 1 luglio 2022 e il 31 dicembre 2022. La chiara dimostrazione della capacità predittiva del modello RNN giustifica nuovamente la sua selezione come scelta finale in quanto miglior modello per la previsione della potenza di produzione di energia solare.



**Figura 26:** Previsioni della potenza di produzione di energia solare ottenute dal modello RNN, 1 luglio 2022 - 31 dicembre 2022.

Esaminando le prestazioni dei modelli per la previsione della potenza di produzione di energia eolica, da Tabella 6, che riporta i risultati delle tre metriche sui dati del *testing set*, emerge una notevole differenza rispetto al contesto della produzione di energia solare. In questo caso non vi è una chiara superiorità delle reti neurali nella comprensione della struttura dei dati rispetto ai modelli alternativi. Osservando specificamente le capacità predittive dei singoli modelli, emerge che il modello LSTM risulta essere il migliore: presenta MAE pari a 163.32, RMSE pari a 208.37 e MAPE uguale a 15.65. Sebbene il modello GRU abbia il valore più basso di MAPE, si è scelto il modello LSTM come migliore opzione, poiché, pur mantenendo performance simili in termini di MAPE, il modello LSTM si distingue nettamente per un MAE e un RMSE inferiori rispetto al modello GRU. La struttura del modello LSTM è rappresentata graficamente in Figura 27. Un ulteriore aspetto notevole emerso da Tabella 7 è che, a differenza del caso della potenza di produzione di energia solare, la capacità predittiva dei modelli per l'energia eolica non diminuisce all'aumentare della distanza dai dati di stima.



**Figura 27:** Rappresentazione grafica della struttura del modello LSTM selezionato per la previsione delle potenza di produzione di energia eolica, dove  $x_i$  indica i nodi di input,  $lstm_i$  indica le celle LSTM,  $d_i$  rappresenta i nodi degli strati densi e  $y_1$  costituisce il nodo di output.

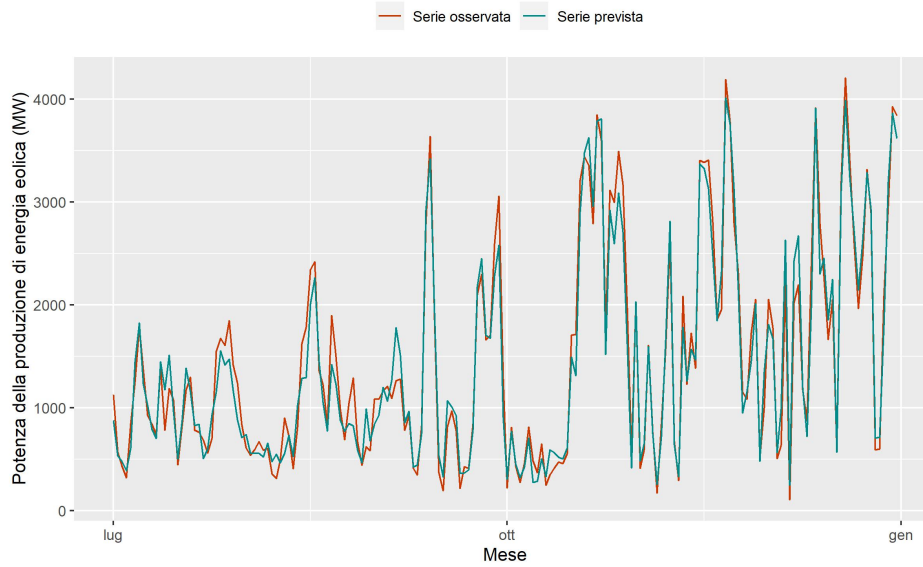
**Tabella 6:** Metriche per la valutazione dell'accuratezza dei modelli per la potenza di produzione di energia eolica. MAE, RMSE e MAPE determinati sull'intero *testing set* ( $MAE$ ,  $RMSE$ ,  $MAPE$ ).

Modello	$MAE$	$RMSE$	$MAPE$
Regressione con errori ARMA	180.46	232.92	16.16
Prophet	176.09	221.18	18.07
NeuarlProphet	169.62	243.59	22.01
RNN	174.49	218.84	18.26
LSTM	<b>163.32</b>	<b>208.37</b>	15.65
GRU	171.93	221.93	<b>15.13</b>

**Tabella 7:** MAPE calcolato al variare di ogni mese del *testing set* per ciascun modello stimato per la potenza di produzione di energia eolica ( $MAPE^L$ ,  $MAPE^A$ ,  $MAPE^S$ ,  $MAPE^O$ ,  $MAPE^N$ ,  $MAPE^D$ ).

Modello	$MAPE^L$	$MAPE^A$	$MAPE^S$	$MAPE^O$	$MAPE^N$	$MAPE^D$
Regressione con errori ARMA	16.43	19.80	16.28	20.12	11.82	<b>12.39</b>
Prophet	15.95	19.07	<b>15.09</b>	17.55	18.98	21.72
NeuarlProphet	17.43	24.89	21.52	22.97	22.82	22.45
RNN	16.65	24.54	26.07	17.66	12.09	12.59
LSTM	15.71	19.52	16.81	16.60	<b>10.14</b>	14.99
GRU	<b>14.34</b>	<b>18.68</b>	17.00	<b>15.79</b>	10.68	14.20

Infine, in Figura 28 sono illustrate le previsioni generate dal modello LSTM e i dati osservati per il periodo dal 1 luglio 2022 al 31 dicembre 2022. L'analisi visiva della figura evidenzia la precisione delle previsioni del modello, confermando la sua selezione come la migliore scelta.



**Figura 28:** Previsioni della potenza di produzione di energia eolica ottenute dal modello LSTM, 1 luglio 2022 - 31 dicembre 2022.

In sintesi, si è evidenziato che il miglior modello per entrambe le serie oggetto di analisi è rappresentato da una rete neurale. Tuttavia, è fondamentale sottolineare che questa constatazione non consente di affermare in modo categorico che modelli più complessi, come le reti neurali, siano sempre dotati di una capacità predittiva superiore rispetto alle alternative.



# 4. Integrazione di Energie Rinnovabili ed Energie Nucleari in un Contesto Pratico


La precisione delle previsioni della potenza di produzione di energia solare ed eolica riveste un ruolo cruciale nell'efficace bilanciamento e regolazione della produzione di energia nucleare. Tale equilibrio si configura come un elemento fondamentale per la gestione ottimale delle risorse energetiche rinnovabili, consentendo una regolazione proattiva della produzione energetica. L'energia rinnovabile e l'energia nucleare possono essere complementari: la disponibilità di energia proveniente da fonti rinnovabili, come il sole e il vento, dipende dalle condizioni meteorologiche, a differenza dell'energia nucleare che può fornire una produzione stabile di energia elettrica in modo continuo, poiché non è influenzata dalle fluttuazioni meteorologiche. Di conseguenza, l'energia nucleare può essere impiegata per integrare l'energia generata da fonti rinnovabili, ottimizzando così l'utilizzo di queste ultime. Già nel 2011, la maggior parte dei reattori nucleari di seconda generazione in esercizio in Europa era stata progettata con solide capacità di regolazione. Queste capacità consentono un adeguamento della produzione su base giornaliera e persino oraria (Lokhov, 2011). Tuttavia, la previsione della produzione energetica rinnovabile non è un compito statico, richiede infatti di adattare continuamente le previsioni in base alle variazioni delle condizioni meteorologiche. La produzione degli impianti solari ed eolici è influenzata da variabili meteorologiche in costante evoluzione e le decisioni riguardanti l'operatività delle centrali nucleari devono essere prese in tempo reale. Pertanto, la seconda parte di questa analisi si concentra su un aspetto cruciale della previsione: la previsione basata sui dati meteorologici previsti. In questa sezione



viene esplorato come il miglior modello identificato nella prima fase dell'analisi possa essere adattato e applicato a dati meteorologici previsti. L'obiettivo principale di questa fase della ricerca è analizzare l'accuratezza di un modello che utilizzi dati meteorologici previsti per stimare la produzione di energia solare ed eolica con una anticipazione pari ad un giorno. Tale modello consentirebbe agli operatori del sistema energetico di prendere decisioni informate e tempestive sulla regolazione della produzione di energia nucleare.

Nella strutturazione del problema, l'approccio ideale implicherebbe l'ampliamento del *training set* man mano che diventano disponibili i dati meteorologici osservati e la potenza di produzione energetica effettiva, consentendo così la generazione di previsioni giornaliere basate sui dati osservati fino all'istante precedente. Tuttavia, va notato che questo procedimento comporta un elevato costo computazionale, poiché richiede la ripetizione della fase di convalida incrociata per la selezione degli iperparametri ogni volta che il *training set* viene aggiornato. Una soluzione pratica è adottare la strategia che prevede la stima di un unico modello sull'intero *training set*, e successivamente si ottengono le previsioni senza aggiornare né gli iperparametri né i parametri della rete neurale. Questa strategia potrebbe mostrare prestazioni inferiori nelle previsioni a più passi avanti, poiché è sensibile all'accumulo dell'errore nel corso della finestra di previsione. Nonostante ciò, questo metodo è stato utilizzato con successo nel prevedere serie temporali reali tramite l'utilizzo di metodi di *machine learning* (Ben Taieb et al., 2012). Per le due serie d'interesse i rispettivi migliori modelli sono stati nuovamente stimati sui dati dal 1 gennaio 2015 al 12 giugno 2023. La fase di convalida incrociata per la selezione degli iperparametri è stata quindi eseguita su un *training set* più ampio rispetto a quello della prima fase dell'analisi, seguendo la procedura descritta in precedenza per le reti neurali. In merito alle variabili esogene del *training set* i valori delle variabili meteorologiche corrispondono ai valori osservati e la capacità installata è stata ottenuta alla stessa maniera della prima fase dell'analisi. Dal momento che sul sito [transparency.entsoe.eu](https://transparency.entsoe.eu) il dato annuale relativo al 2023 della capacità installata è aggiornato al 15 dicembre 2022, e quindi risulta datato, tale informazione è stata reperita tramite il sito [datahub.ren.pt](https://datahub.ren.pt) che fornisce tale dato relativamente al mese di settembre 2023. Sempre dal sito [open-meteo.com](https://open-meteo.com) sono state ricavate le previsioni meteorologiche con un giorno d'anticipo per le variabili *Temperature (2 m)*, *Sealevel Preassure*, *Direct Normal Irradiance (DNI)*, *Cloudcover Total*, *Wind*

*Speed (80 m)* e *Wind Speed (120 m)* dal 13 giugno 2023 al 2 settembre 2023 per ciascuna delle nove città portoghesi prese in considerazione nell’analisi. Dal momento che le previsioni per la variabile *Wind Speed (100 m)* non sono disponibili sul sito open-meteo.com, questa è stata ricavata dalla media delle previsioni della velocità del vento a 80 metri e a 120 metri d’altezza. Per rendere la fase di previsione più verosimile possibile, al generico istante di previsione  $h$  è stato scelto di comporre il *testing set* nel modo seguente: fino all’istante  $h - 1$  le variabili meteorologiche riportano i valori osservati, mentre all’istante  $h$  si trovano le previsioni fatte con un giorno d’anticipo per le stesse variabili. Tale metodologia è raffigurata in Figura 29.

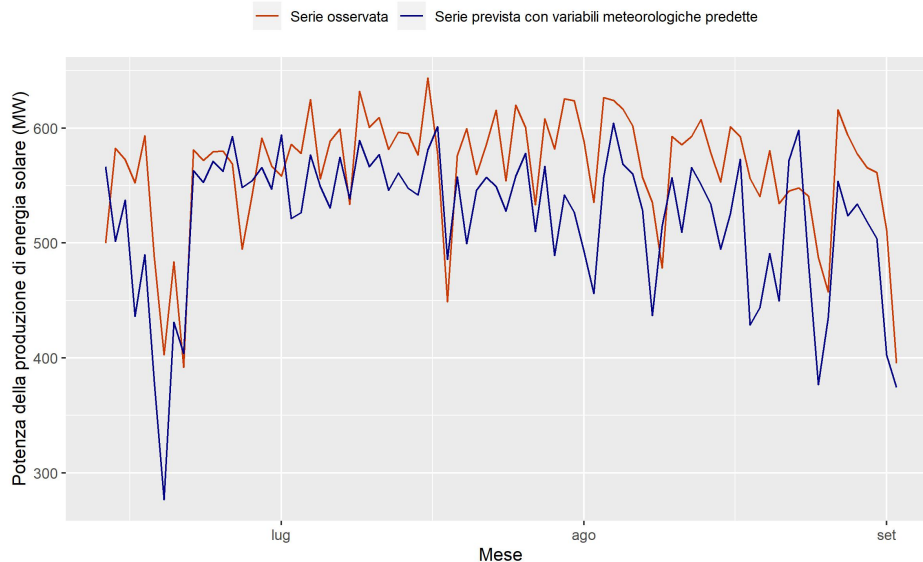


**Figura 29:** Composizione del *testing set* al variare dell’istante di previsione.

In questo modo non viene introdotto nel modello ulteriore incertezza legata alle previsioni meteorologiche ai giorni precedenti rispetto al passo di previsione. Per quanto riguarda la capacità installata degli impianti solari ed eolici, si può affermare che tali valori sono considerati facilmente prevedibili, poiché sono strettamente legati alla pianificazione e alla costruzione di nuovi impianti. Di conseguenza, le informazioni rilevanti sono generalmente disponibili con un notevole anticipo e con un buon grado di certezza. Per tale ragione vengono utilizzati i valori annuali osservati della capacità installata degli impianti solari ed eolici, trasformati come fatto durante la prima fase dell’analisi.

Come dimostrato in precedenza, il miglior modello per la previsione della potenza di produzione di energia solare risulta essere il modello RNN con un unico strato ricorrente. La nuova procedura di convalida incrociata porta alla selezione di una rete con 10 nodi nello strato ricorrente, funzione di attivazione tangente iperbolica, *dropout rate* pari a 0 e *learning rate* uguale a 0.01. Inoltre, *batch size* risulta essere pari a 500 ed *epochs* pari a 200. Per valutare l’accuratezza delle previsioni ottenute a partire dalle variabili meteorologiche


predette, viene determinato il valore dell'errore assoluto percentuale (APE) per ciascuna delle 82 previsioni. Il valore medio di questa misura d'errore, che corrisponde al MAPE, risulta essere uguale a 10.61, con deviazione standard pari a 8.08. Il confronto tra il valore del MAPE ottenuto in questa fase dell'analisi con il MAPE risultante dalla prima fase, porta alla conclusione che l'utilizzo delle variabili meteorologiche predette comporta una perdita di accuratezza nelle previsioni. Infatti, confrontando tale valore con i valori del MAPE ottenuti per i primi tre mesi dei *testing set* della prima fase dell'analisi (i quali risultano essere rispettivamente pari a 4.25, 5.82 e 13.72), è possibile notare una moderata diminuzione della capacità predittiva del modello. In Figura 30 viene rappresentata la serie delle previsioni ottenute con le variabili meteorologiche predette e la serie della potenza di produzione di energia solare osservata. Da tale grafico si nota che generalmente le previsioni assumono valori inferiori rispetto a quelli osservati.



**Figura 30:** Previsioni della potenza di produzione di energia solare ottenute dal modello RNN con l'utilizzo delle variabili meteorologiche predette, 13 giugno 2023 - 2 settembre 2023.


Per esaminare se l'errore sia attribuibile all'utilizzo delle variabili meteorologiche predette, sono state effettuate previsioni equivalenti basate sull'utilizzo delle medesime variabili osservate. Tali previsioni risultano avere MAPE pari a 5.63, con deviazione standard uguale a 4.73. Per il confronto delle metriche, in Figura 31 sono illustrate le distribuzioni empiriche dell'APE relative alle previsioni effettuate utilizzando le variabili meteorologiche predette e

quelle basate sulle variabili meteorologiche osservate. Dal grafico è evidente come la distribuzione dell'errore delle previsioni basate sui dati meteorologici osservati sia maggiormente concentrata verso valori minori rispetto alla distribuzione dell'errore delle previsioni basate sulle variabili meteorologiche predette.



**Figura 31:** (a): Grafico a violino dell'APE determinato per ciascuna previsione della potenza di produzione di energia solare basata sulle variabili meteorologiche predette. (b): Grafico a violino dell'APE determinato per ciascuna previsione della potenza di produzione di energia solare basata sulle variabili meteorologiche osservate.

L'analisi grafica delle previsioni in questione può essere effettuata osservando Figura 32, dalla quale emerge che le previsioni non seguono lo stesso andamento delle previsioni basate sulle variabili meteorologiche predette, ovvero non mostrano la tendenza a sottostimare i valori osservati.




**Figura 32:** Previsioni della potenza di produzione di energia solare ottenute dal modello RNN con l'utilizzo delle variabili meteorologiche osservate, 13 giugno 2023 - 2 settembre 2023.

Per approfondire ulteriormente la questione legata all'errore nelle previsioni della potenza di produzione di energia solare, sono state confrontate le serie delle variabili meteorologiche predette e osservate. Da tale analisi è emerso che le serie relative alla copertura nuvolosa prevista assumono prevalentemente valori maggiori rispetto a quelli osservati, come si nota da Figura A21. Il valore dell'errore medio percentuale (MPE) determinato sui dati raggruppati mensilmente per le serie relative alla copertura nuvolosa risulta essere complessivamente pari a -99.2. Per quanto concerne le serie dell'irradiazione solare e della temperatura, queste risultano essere maggiormente accurate: i valori del MPE sono rispettivamente uguali a 8.35 e -2.20. Essendo noto che maggiore è la copertura nuvolosa, minore risulta essere la potenza di produzione di energia solare (Chikate, 2015), l'errore commesso nella previsione della copertura nuvolosa potrebbe spiegare perché si assiste a previsioni della potenza di produzione di energia solare generalmente inferiori rispetto ai dati osservati quando vengono utilizzate le variabili meteorologiche predette. Tuttavia, tenendo conto che il modello in esame è una rete neurale, e di conseguenza rappresenta un modello "a scatola nera" (*black box*), risulta di difficile interpretazione e non è possibile confermare con facilità ipotesi sul ruolo assunto dalle variabili esogene nel funzionamento interno del modello (Benitez et al., 1997). Pertanto, i risultati relativi alle variabili meteorologiche predette e osservate devono

essere esclusivamente considerati come indicazioni e possibili spiegazioni dell'errore.


Relativamente alla serie della potenza di produzione di energia eolica, dalla prima fase di analisi il miglior modello risulta essere il modello LSTM con tre strati che presentano celle di tipo LSTM. Ripetendo la fase di convalida incrociata si ottengono i valori ottimali per gli iperparametri, questi risultano essere: numero di nodi per strato latente pari a 10, funzione di attivazione ELU, *dropout rate* uguale a 0.1 e *learning rate* pari a 0.01. Inoltre, sono stati selezionati *batch size* pari a 500 ed *epochs* uguale a 200. Al fine di valutare l'accuratezza delle previsioni della potenza di produzione di energia eolica ottenute a partire dalle variabili meteorologiche predette, per ciascuna delle 82 osservazioni giornaliere viene determinato il valore dell'APE. Questo assume valore medio pari a 14.69 con deviazione standard uguale a 12.18. Tale valore risulta essere in linea con il valore del MAPE ottenuto nella prima fase dell'analisi (15.65). Analizzando graficamente le previsioni tramite Figura 33, si evince che il modello risulta avere una capacità predittiva soddisfacente: riesce ad individuare con sufficiente accuratezza l'andamento della serie ed i suoi picchi.



**Figura 33:** Previsioni della potenza di produzione di energia eolica ottenute dal modello LSTM con l'utilizzo delle variabili meteorologiche predette, 13 giugno 2023 - 2 settembre 2023.


Vengono successivamente ottenute le previsioni sul medesimo *testing set* basate sull'utilizzo delle variabili meteorologiche osservate. Per tali previsioni il valore del MAPE risulta essere uguale a 12.75, con deviazione standard pari a 13.42. Tramite il confronto dei valori del

MAPE è possibile stabilire che con l'introduzione delle variabili meteorologiche predette si osserva un lieve peggioramento in termini di accuratezza delle previsioni. In Figura 34 sono rappresentate le distribuzioni empiriche dei valori dell'APE per le due previsioni in analisi, da tale grafico si evince che la distribuzione relativa all'APE delle previsioni ottenute a partire dalle variabili meteorologiche osservate è leggermente più concentrata verso valori più bassi rispetto alla distribuzione alternativa.



**Figura 34:** (a): Grafico a violino dell'APE determinato per ciascuna previsione della potenza di produzione di energia eolica basata sulle variabili meteorologiche predette. (b): Grafico a violino dell'APE determinato per ciascuna previsione della potenza di produzione di energia eolica basata sulle variabili meteorologiche osservate.

Infine, in Figura 35 viene rappresentato il grafico della serie della potenza di produzione di energia eolica osservata e la serie delle previsioni ottenute a partire dalle variabili meteorologiche osservate. Confrontano tale grafico con quello di Figura 33, viene confermato quanto dedotto in precedenza: le previsioni ottenute a partire dalle variabili meteorologiche osservate risultano essere maggiormente accurate, seppur con un lieve miglioramento, rispetto a quelle ottenute dalle previsioni meteorologiche.



**Figura 35:** Previsioni della potenza di produzione di energia eolica ottenute dal modello LSTM con l'utilizzo delle variabili meteorologiche osservate, 13 giugno 2023 - 2 settembre 2023.

In conclusione, i risultati ottenuti dimostrano in modo inequivocabile l'importanza delle variabili meteorologiche nella produzione energetica solare ed eolica. L'introduzione di previsioni meteorologiche, sebbene fondamentale per consentire una previsione più anticipata della produzione energetica, ha comportato una diminuzione dell'accuratezza delle previsioni stesse. Questo risultato sottolinea il fatto che le variabili meteorologiche giocano un ruolo significativo nella determinazione della produzione energetica da fonti rinnovabili. In generale, per migliorare la precisione delle previsioni del modello, possono essere eseguite procedure di stima più complesse o più intensive in termini di risorse computazionali, come l'aggiornamento del *training set* e la ripetizione della fase di convalida incrociata ad ogni passo di previsione. Oltre a questa strategia esistono soluzioni intermedie che prevedono, ad esempio, un'unica iniziale fase di convalida incrociata per la selezione degli iperparametri e l'aggiornamento delle stime dei parametri sulla base dei nuovi dati osservati ad ogni istante di previsione. Poiché questo approccio ha un basso impatto in termini di risorse computazionali, è stato esaminato ma i risultati ottenuti sono risultati meno soddisfacenti rispetto alla strategia adottata. Nonostante la diminuzione dell'accuratezza introdotta dalle previsioni meteorologiche, queste rimangono uno strumento indispensabile per adattare in modo proattivo la produzione energetica alle fluttuazioni atmosferiche e per garantire una gestione



efficiente e affidabile delle risorse energetiche rinnovabili. Pertanto, l'interconnessione tra variabili meteorologiche e produzione di energia da fonti rinnovabili deve essere considerata con attenzione nella gestione e nell'ottimizzazione dell'energia rinnovabile.



## 5. Conclusioni

Questa tesi si è posta l'obiettivo di esaminare e confrontare diversi modelli di previsione per le serie storiche di produzione di energia solare ed eolica in Portogallo, in un contesto in cui la transizione verso fonti di energia rinnovabile è al centro dell'attenzione. Come sottolineato nell'introduzione, il Portogallo sta compiendo progressi significativi verso un futuro energetico basato principalmente su fonti rinnovabili, rendendo cruciale la previsione accurata della produzione di energia da queste fonti.

Nella prima fase della ricerca, sono stati analizzati approfonditamente i dati e i modelli selezionati per la previsione della potenza di produzione di energia solare ed eolica, utilizzando dati meteorologici osservati. Dai risultati ottenuti dalle analisi svolte durante questa fase è emerso chiaramente che l'approccio migliore per la previsione della serie della potenza di produzione di energia solare è rappresentato dal modello RNN. Allo stesso tempo, per la serie della potenza di produzione di energia eolica il modello LSTM si è dimostrato il più accurato. Analizzando più nel dettaglio la performance di tutti i modelli, non è stato possibile stabilire la presenza di un modello o di un gruppo di modelli con caratteristiche comuni con una netta superiore capacità predittiva rispetto alle alternative. Come è stato osservato, per la serie della potenza di produzione di energia solare i modelli che presentano una struttura di rete neurale sono risultati essere i modelli con maggiore accuratezza, mentre per la serie della potenza di produzione di energia eolica gli stessi modelli non hanno mostrato una capacità predittiva costantemente migliore rispetto alle alternative. Da questa osservazione è possibile concludere che la scelta del miglior modello è fortemente dipendente dalla struttura dei dati stessa. Tramite le analisi svolte durante la seconda fase della ricerca, è stato osservato che l'accuratezza dei modelli è diminuita quando sono state utilizzate le variabili meteorologiche previste anziché quelle osservate. Riguardo la serie della potenza di produzione di energia

solare, nella prima fase dell'analisi è stato notato che le performance del modello RNN si deteriorano man mano che aumenta l'intervallo di tempo tra le previsioni e i dati utilizzati per addestrare il modello stesso. In considerazione di questo fenomeno, nonostante il MAPE nella seconda fase sia inferiore a quello ottenuto nella prima, è corretto affermare che si è verificata una perdita di accuratezza quando le variabili meteorologiche osservate sono state sostituite con quelle previste. Confrontando infatti i valori del MAPE ottenuti nella prima fase per i primi tre mesi del *testing set*, si può concludere che l'utilizzo delle variabili meteorologiche previste comporta una diminuzione dell'accuratezza. Questo risultato era stato inoltre confermato dal confronto effettuato sullo stesso *testing set* della seconda fase tra le previsioni basate sui dati meteorologici predetti e quelle basate sui dati meteorologici osservati. Una diminuzione dell'accuratezza, seppur nettamente meno accentuata, è stata osservata anche per la serie della potenza di produzione di energia eolica. Tramite il confronto svolto durante la seconda fase dell'analisi, è emerso che tale sostituzione ha comportato un lieve peggioramento della capacità predittiva del modello. Questi risultati evidenziano nel complesso la forte influenza delle condizioni meteorologiche sulla produzione di energia solare ed eolica, e la rilevanza della accuratezza di tali informazioni per la previsione delle fonti energetiche rinnovabili. Un ulteriore aspetto importante emerso da questa ricerca riguarda i limiti legati al costo computazionale associato alla fase di stima delle reti neurali. In particolare, il processo di convalida incrociata richiede un notevole dispendio di risorse computazionali. Proprio per questa ragione non è stato possibile effettuare una ricerca esaustiva dei migliori iperparametri, ma è stato necessario limitare la ricerca ad un set casuale di 500 combinazioni di valori. Questo rappresenta una criticità saliente dei modelli complessi come le reti neurali, poiché il costo computazionale può aumentare in modo significativo con la complessità del modello o l'espansione del set di dati. In futuro, per affrontare queste sfide, potrebbero essere esplorate strategie di ottimizzazione computazionale e l'implementazione di tecniche avanzate di addestramento, al fine di ridurre i tempi di calcolo e migliorare così l'efficienza delle previsioni tramite l'utilizzo di modelli stimati in maniera più approfondita.

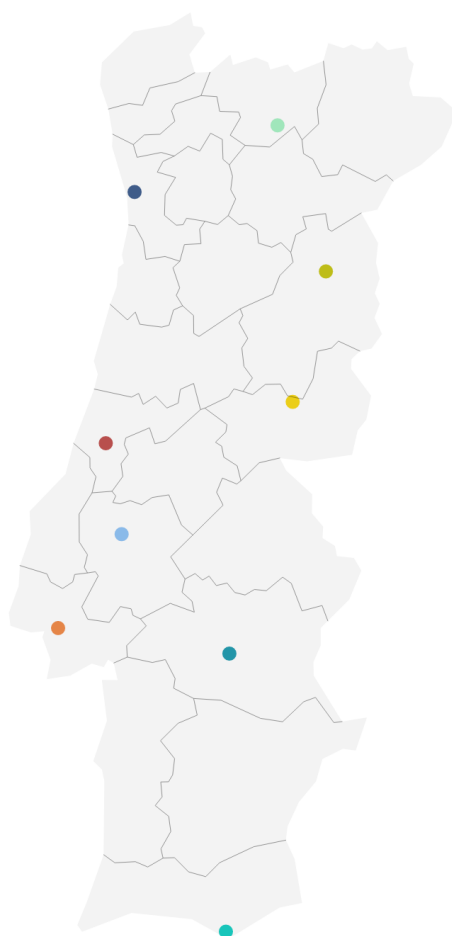
In definitiva, si spera che questa tesi abbia fornito indicazioni preziose per la selezione dei modelli di previsione nel contesto della produzione energetica rinnovabile. Tuttavia, rimangono sfide significative da affrontare nell'ottica di migliorare ulteriormente l'accuratezza

delle previsioni e l'efficienza computazionale, alla luce dell'importanza sempre crescente delle fonti energetiche rinnovabili nella transizione verso un futuro energetico sostenibile.



## 6. Appendice


Castelo Branco Evora Faro Guarda Leiria Lisbona Porto Santarém Vila Real




Created with Datawrapper

**Figura A1:** Posizione geografica delle città portoghesi Castelo Branco, Evora, Faro, Guarda, Leiria, Lisbona, Porto, Santarém e Vila Real.

Il grafico è stato creato attraverso il sito [app.datawrapper.de](http://app.datawrapper.de)




**Figura A2:** Serie giornaliera lisciata con loess della temperatura media, per le città portoghesi Castelo Branco, Evora, Faro, Guarda, Leiria, Lisbona, Porto, Santarém e Vila Real, 1 gennaio 2015 - 30 giugno 2022.




**Figura A3:** Serie giornaliera lisciata con loess della pressione media a livello del mare, per le città portoghesi Castelo Branco, Evora, Faro, Guarda, Leiria, Lisbona, Porto, Santarém e Vila Real, 1 gennaio 2015 - 30 giugno 2022.

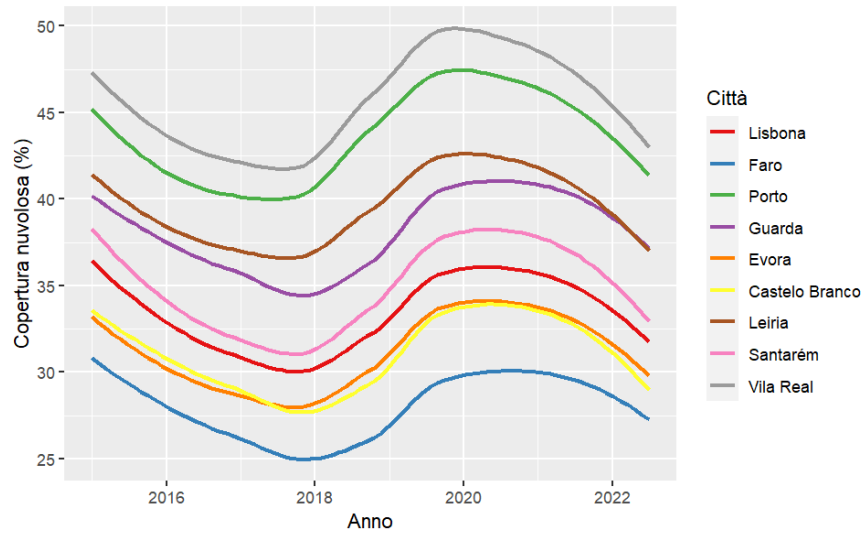





**Figura A4:** Serie giornaliera lisciata con loess della velocità media del vento a 100 metri dal suolo, per le città portoghesi Castelo Branco, Evora, Faro, Guarda, Leiria, Lisbona, Porto, Santarém e Vila Real, 1 gennaio 2015 - 30 giugno 2022.




**Figura A5:** Serie giornaliera lisciata con loess della irradiazione solare media, per le città portoghesi Castelo Branco, Evora, Faro, Guarda, Leiria, Lisbona, Porto, Santarém e Vila Real, 1 gennaio 2015 - 30 giugno 2022.




**Figura A6:** Serie giornaliera lisciata con loess della copertura nuvolosa media, per le città portoghesi Castelo Branco, Evora, Faro, Guarda, Leiria, Lisbona, Porto, Santarém e Vila Real, 1 gennaio 2015 - 30 giugno 2022.




**Figura A7:** Serie giornaliera della capacità totale installata degli impianti fotovoltaici in Portogallo, 1 gennaio 2015 - 30 giugno 2022.




**Figura A8:** Serie giornaliera della capacità totale installata degli impianti eolici in Portogallo, 1 gennaio 2015 - 30 giugno 2022.




**Figura A9:** (a): ACF della serie della potenza di produzione di energia solare, 1 gennaio 2015 - 30 giugno 2022. (b): PACF della serie della potenza di produzione di energia solare, 1 gennaio 2015 - 30 giugno 2022.




**Figura A10:** (a): ACF della serie della potenza di produzione di energia eolica, 1 gennaio 2015 - 30 giugno 2022. (b): PACF della serie della potenza di produzione di energia eolica, 1 gennaio 2015 - 30 giugno 2022.




**Figura A11:** Previsioni della potenza di produzione di energia solare ottenute dal modello di regressione con errori ARMA, 1 luglio 2022 - 31 dicembre 2022.




**Figura A12:** Previsioni della potenza di produzione di energia solare ottenute dal modello Prophet, 1 luglio 2022 - 31 dicembre 2022.




**Figura A13:** Previsioni della potenza di produzione di energia solare ottenute dal modello NeuarlProphet, 1 luglio 2022 - 31 dicembre 2022.




**Figura A14:** Previsioni della potenza di produzione di energia solare ottenute dal modello LSTM, 1 luglio 2022 - 31 dicembre 2022.




**Figura A15:** Previsioni della potenza di produzione di energia solare ottenute dal modello GRU, 1 luglio 2022 - 31 dicembre 2022.




**Figura A16:** Previsioni della potenza di produzione di energia eolica ottenute dal modello di regressione con errori ARMA, 1 luglio 2022 - 31 dicembre 2022.



**Figura A17:** Previsioni della potenza di produzione di energia eolica ottenute dal modello Prophet, 1 luglio 2022 - 31 dicembre 2022.




**Figura A18:** Previsioni della potenza di produzione di energia eolica ottenute dal modello NeuarlProphet, 1 luglio 2022 - 31 dicembre 2022.



**Figura A19:** Previsioni della potenza di produzione di energia eolica ottenute dal modello RNN, 1 luglio 2022 - 31 dicembre 2022.





**Figura A20:** Previsioni della potenza di produzione di energia eolica ottenute dal modello GRU, 1 luglio 2022 - 31 dicembre 2022.

**Tabella A1:** Stime dei coefficienti del modello di regressione con errori ARMA per la serie della potenza della produzione di energia solare.

	Coefficiente
ar1	1.43
ar2	$-4.37 \cdot 10^{-1}$
ma1	$-9.81 \cdot 10^{-1}$
ma2	$8.17 \cdot 10^{-2}$
intercept	$-6.53 \cdot 10^{-1}$
temperatura_LISBONA	$-3.90 \cdot 10^{-1}$
irradiazione_solare_LISBONA	$6.04 \cdot 10^{-2}$
copertura_nuvole_LISBONA	$-2.30 \cdot 10^{-2}$
temperatura_FARO	$5.78 \cdot 10^{-1}$
irradiazione_solare_FARO	$9.73 \cdot 10^{-2}$
copertura_nuvole_FARO	$-1.51 \cdot 10^{-1}$
temperatura_PORTO	$-9.29 \cdot 10^{-1}$
irradiazione_solare_PORTO	$3.67 \cdot 10^{-2}$
copertura_nuvole_PORTO	$3.83 \cdot 10^{-2}$
temperatura_GUARDA	-3.32
irradiazione_solare_GUARDA	$1.45 \cdot 10^{-2}$
copertura_nuvole_GUARDA	$-1.02 \cdot 10^{-2}$
temperatura_EVORA	-1.60
irradiazione_solare_EVORA	$8.24 \cdot 10^{-2}$
copertura_nuvole_EVORA	$-9.50 \cdot 10^{-2}$
temperatura_CASTELOBRANCO	3.06
irradiazione_solare_CASTELOBRANCO	$3.04 \cdot 10^{-2}$
copertura_nuvole_CASTELOBRANCO	$-1.48 \cdot 10^{-1}$
temperatura_LEIRIA	1.08
irradiazione_solare_LEIRIA	$5.60 \cdot 10^{-2}$
copertura_nuvole_LEIRIA	$-4.23 \cdot 10^{-2}$
temperatura_SANTAREM	$-8.84 \cdot 10^{-2}$
irradiazione_solare_SANTAREM	$-4.50 \cdot 10^{-2}$
copertura_nuvole_SANTAREM	$5.25 \cdot 10^{-2}$
temperatura_VILAREAL	1.14
irradiazione_solare_VILAREAL	$-4.37 \cdot 10^{-3}$
copertura_nuvole_VILAREAL	$1.36 \cdot 10^{-1}$
CapacitaSolare	$3.07 \cdot 10^{-1}$

**Tabella A2:** Stime dei coefficienti del modello di regressione con errori ARMA per la serie della potenza della produzione di energia eolica.

	Coefficiente
ar1	1.26
ar2	-0.28
ma1	-0.94
intercept	-5911.56
temperatura_LISBONA	-1.51
pressione_LM_LISBONA	-168.84
velocità_vento_100m_LISBONA	-5.25
temperatura_FARO	-24.50
pressione_LM_FARO	-14.99
velocità_vento_100m_FARO	11.42
temperatura_PORTO	60.52
pressione_LM_PORTO	58.89
velocità_vento_100m_PORTO	1.45
temperatura_GUARDA	76.35
pressione_LM_GUARDA	166.91
velocità_vento_100m_GUARDA	36.37
temperatura_EVORA	-0.29
pressione_LM_EVORA	92.80
velocità_vento_100m_EVORA	3.31
temperatura_CASTELOBRANCO	-54.03
pressione_LM_CASTELOBRANCO	-193.53
velocità_vento_100m_CASTELOBRANCO	6.81
temperatura_LEIRIA	4.76
pressione_LM_LEIRIA	77.25
velocità_vento_100m_LEIRIA	29.03
temperatura_SANTAREM	2.73
pressione_LM_SANTAREM	170.59
velocità_vento_100m_SANTAREM	4.10
temperatura_VILAREAL	-64.80
pressione_LM_VILAREAL	-185.07
velocità_vento_100m_VILAREAL	58.98
CapacitaEolico	0.22

**Tabella A3:** Stime dei coefficienti del modello Prophet per la serie della potenza della produzione di energia solare.

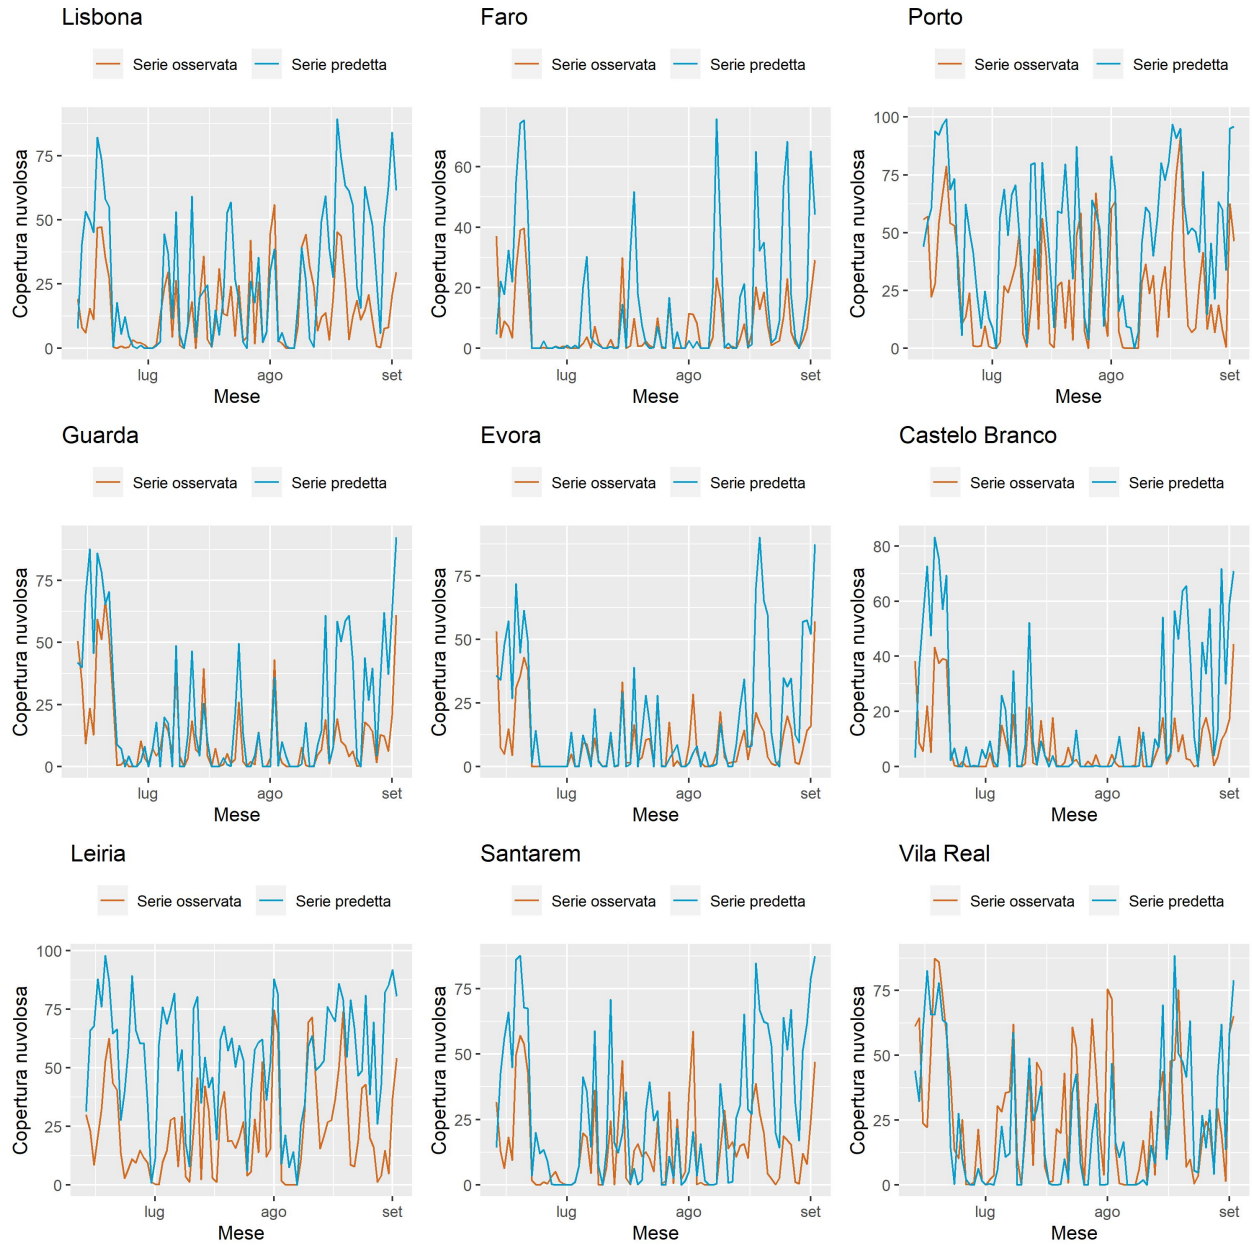
Regressore	Coefficiente
temperatura_LISBONA	$-1.14 \cdot 10^{-2}$
irradiazione_solare_LISBONA	$1.17 \cdot 10^{-2}$
copertura_nuvole_LISBONA	$-7.19 \cdot 10^{-3}$
temperatura_FARO	$3.19 \cdot 10^{-3}$
irradiazione_solare_FARO	$2.51 \cdot 10^{-2}$
copertura_nuvole_FARO	$-1.58 \cdot 10^{-3}$
irradiazione_solare_PORTO	$1.29 \cdot 10^{-2}$
copertura_nuvole_PORTO	$-1.06 \cdot 10^{-3}$
temperatura_PORTO	$-5.01 \cdot 10^{-3}$
temperatura_GUARDA	$-3.89 \cdot 10^{-2}$
irradiazione_solare_GUARDA	$2.37 \cdot 10^{-3}$
copertura_nuvole_GUARDA	$3.71 \cdot 10^{-3}$
temperatura_EVORA	$-6.58 \cdot 10^{-3}$
irradiazione_solare_EVORA	$2.01 \cdot 10^{-2}$
copertura_nuvole_EVORA	$-3.43 \cdot 10^{-3}$
temperatura_CASTELOBRANCO	$2.05 \cdot 10^{-2}$
irradiazione_solare_CASTELOBRANCO	$6.51 \cdot 10^{-3}$
copertura_nuvole_CASTELOBRANCO	$-6.75 \cdot 10^{-3}$
temperatura_LEIRIA	$2.29 \cdot 10^{-2}$
irradiazione_solare_LEIRIA	$2.44 \cdot 10^{-2}$
copertura_nuvole_LEIRIA	$4.23 \cdot 10^{-3}$
temperatura_SANTAREM	$-2.09 \cdot 10^{-2}$
irradiazione_solare_SANTAREM	$-9.53 \cdot 10^{-3}$
copertura_nuvole_SANTAREM	$2.27 \cdot 10^{-3}$
temperatura_VILAREAL	$1.83 \cdot 10^{-2}$
irradiazione_solare_VILAREAL	$-3.07 \cdot 10^{-4}$
copertura_nuvole_VILAREAL	$2.02 \cdot 10^{-2}$
CapacitaSolare	$4.30 \cdot 10^{-2}$
Lag_1	$3.60 \cdot 10^{-2}$
Lag_2	$5.47 \cdot 10^{-3}$
Lag_3	$5.32 \cdot 10^{-3}$
Lag_4	$5.86 \cdot 10^{-3}$
Lag_5	$1.69 \cdot 10^{-3}$

Regressore	Coefficiente
Lag_6	$7.82 \cdot 10^{-4}$
Lag_7	$1.07 \cdot 10^{-3}$
Lag_8	$3.09 \cdot 10^{-3}$
Lag_9	$8.07 \cdot 10^{-4}$
Lag_10	$-2.11 \cdot 10^{-3}$
Lag_11	$6.20 \cdot 10^{-3}$
Lag_12	$6.08 \cdot 10^{-3}$
Lag_13	$6.80 \cdot 10^{-3}$
Lag_14	$1.11 \cdot 10^{-3}$
Lag_15	$5.50 \cdot 10^{-3}$
Lag_16	$-2.91 \cdot 10^{-3}$
Lag_17	$1.51 \cdot 10^{-3}$
Lag_18	$-4.63 \cdot 10^{-3}$
Lag_19	$7.76 \cdot 10^{-3}$
Lag_20	$3.40 \cdot 10^{-3}$
Lag_21	$1.00 \cdot 10^{-3}$
Lag_22	$1.34 \cdot 10^{-3}$
Lag_23	$-2.09 \cdot 10^{-3}$
Lag_24	$3.32 \cdot 10^{-3}$
Lag_25	$1.21 \cdot 10^{-3}$
Lag_26	$4.08 \cdot 10^{-3}$
Lag_27	$-5.70 \cdot 10^{-4}$
Lag_28	$8.08 \cdot 10^{-3}$
Lag_29	$-2.04 \cdot 10^{-3}$
Lag_30	$6.65 \cdot 10^{-3}$

**Tabella A4:** Stime dei coefficienti del modello Prophet per la serie della potenza della produzione di energia eolica.

Regressore	Coefficiente
temperatura_LISBONA	$1.51 \cdot 10^{-2}$
velocità_vento_100m_LISBONA	$-2.00 \cdot 10^{-2}$
temperatura_FARO	$-2.36 \cdot 10^{-2}$
pressione_LM_FARO	$-6.14 \cdot 10^{-2}$
velocità_vento_100m_FARO	$1.92 \cdot 10^{-2}$
temperatura_PORTO	$5.26 \cdot 10^{-2}$
pressione_LM_PORTO	$1.99 \cdot 10^{-2}$
velocità_vento_100m_PORTO	$2.02 \cdot 10^{-3}$
temperatura_GUARDA	$9.72 \cdot 10^{-2}$
pressione_LM_GUARDA	$1.85 \cdot 10^{-1}$
velocità_vento_100m_GUARDA	$6.14 \cdot 10^{-2}$
temperatura_EVORA	$1.25 \cdot 10^{-3}$
pressione_LM_EVORA	$1.49 \cdot 10^{-1}$
velocità_vento_100m_EVORA	$4.28 \cdot 10^{-3}$
temperatura_CASTELOBRANCO	$-6.72 \cdot 10^{-2}$
pressione_LM_CASTELOBRANCO	$-1.97 \cdot 10^{-1}$
velocità_vento_100m_CASTELOBRANCO	$8.44 \cdot 10^{-3}$
temperatura_LEIRIA	$1.71 \cdot 10^{-3}$
pressione_LM_LEIRIA	$1.42 \cdot 10^{-1}$
velocità_vento_100m_LEIRIA	$5.37 \cdot 10^{-2}$
temperatura_SANTAREM	$-2.02 \cdot 10^{-2}$
pressione_LM_SANTAREM	$2.71 \cdot 10^{-2}$
velocità_vento_100m_SANTAREM	$1.40 \cdot 10^{-2}$
temperatura_VILAREAL	$-5.78 \cdot 10^{-2}$
pressione_LM_VILAREAL	$-1.83 \cdot 10^{-2}$
velocità_vento_100m_VILAREAL	$7.36 \cdot 10^{-2}$
CapacitaEolico	$6.25 \cdot 10^{-3}$
Lag_1	$1.12 \cdot 10^{-2}$
Lag_2	$-6.10 \cdot 10^{-3}$
Lag_3	$1.23 \cdot 10^{-3}$
Lag_4	$-6.92 \cdot 10^{-4}$
Lag_5	$7.67 \cdot 10^{-4}$

Regressore	Coefficiente
Lag_6	$1.84 \cdot 10^{-4}$
Lag_7	$-3.13 \cdot 10^{-4}$
Lag_8	$1.77 \cdot 10^{-3}$
Lag_9	$-9.59 \cdot 10^{-4}$
Lag_10	$-1.10 \cdot 10^{-4}$
Lag_11	$-7.44 \cdot 10^{-4}$
Lag_12	$2.73 \cdot 10^{-3}$
Lag_13	$2.19 \cdot 10^{-5}$
Lag_14	$-1.45 \cdot 10^{-4}$
Lag_15	$2.50 \cdot 10^{-3}$
Lag_16	$-4.06 \cdot 10^{-3}$
Lag_17	$2.36 \cdot 10^{-3}$
Lag_18	$5.10 \cdot 10^{-4}$
Lag_19	$5.23 \cdot 10^{-4}$
Lag_20	$-3.36 \cdot 10^{-4}$
Lag_21	$2.08 \cdot 10^{-4}$
Lag_22	$3.00 \cdot 10^{-4}$
Lag_23	$8.96 \cdot 10^{-4}$
Lag_24	$-8.32 \cdot 10^{-4}$
Lag_25	$3.40 \cdot 10^{-3}$
Lag_26	$-3.87 \cdot 10^{-3}$
Lag_27	$3.94 \cdot 10^{-4}$
Lag_28	$-1.43 \cdot 10^{-3}$
Lag_29	$1.66 \cdot 10^{-3}$
Lag_30	$5.52 \cdot 10^{-4}$



**Figura A21:** Previsioni della copertura nuvolosa per le nove città portoghesi, 13 giugno 2023 - 2 settembre 2023.





## 6. Bibliografia

Directive (EU) 2018/2001 of the European Parliament and of the Council of 11 December 2018 on the promotion of the use of energy from renewable sources (recast) (Text with EEA relevance.) (2018, dicembre 11).

*Accordo di Parigi sui cambiamenti climatici.* (2015). Recuperato settembre 28, 2023, da <https://www.consilium.europa.eu/it/policies/climate-change/paris-agreement/>

OECD & Nuclear Energy Agency. (2012, novembre 7). *Nuclear energy and renewables: System effects in low-carbon electricity systems.* <https://doi.org/10.1787/9789264188617-en>

*Ren - redes energéticas nacionais.* (2023, settembre 24). Recuperato settembre 24, 2023, da <https://www.ren.pt/en-gb>

Almasarweh, M., & Wadi, S. A. (2018). ARIMA model in predicting banking stock market data. *Modern Applied Science*, 12(11), 309. <https://doi.org/10.5539/mas.v12n11p309>

Aditya Satrio, C. B., Darmawan, W., Nadia, B. U., & Hanafiah, N. (2021). Time series analysis and forecasting of coronavirus disease in Indonesia using ARIMA model and PROPHET. *Procedia Computer Science*, 179, 524–532. <https://doi.org/10.1016/j.procs.2021.01.036>

Triebe, O., Hewamalage, H., Pilyugina, P., Laptev, N., Bergmeir, C., & Rajagopal, R. (2021, novembre 29). NeuralProphet: Explainable Forecasting at Scale. <https://doi.org/10.48550/arXiv.2111.15397>

Comment: NeuralProphet can be installed with pip or from [https://github.com/ourownstory/neural\\_prophet](https://github.com/ourownstory/neural_prophet)  
- Documentation is available at <https://neuralprophet.com>

Zhang, G. P. (2003). Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*, 50, 159–175. [https://doi.org/10.1016/S0925-2312\(01\)00702-](https://doi.org/10.1016/S0925-2312(01)00702-0)

0

- Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9(8), 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- International Energy Agency. (2021, luglio 9). *Portugal 2021 energy policy review*. OECD. <https://doi.org/10.1787/3b485e25-en>
- Statistics Portugal - Web Portal*. (2023, marzo 22). Recuperato marzo 22, 2023, da [https://www.ine.pt/xportal/xmain?xpgid=ine\\_tema&xpid=INE&tema\\_cod=1211](https://www.ine.pt/xportal/xmain?xpgid=ine_tema&xpid=INE&tema_cod=1211)
- Köppen, W. (1900). Versuch einer Klassifikation der Klimate, vorzugsweise nach ihren Beziehungen zur Pflanzenwelt [Publisher: Franz Steiner Verlag]. *Geographische Zeitschrift*, 6(11), 593–611.
- Peel, M. C., Finlayson, B. L., & McMahon, T. A. (2007). Updated world map of the Köppen-Geiger climate classification [Publisher: Copernicus GmbH]. *Hydrology and Earth System Sciences*, 11(5), 1633–1644. <https://doi.org/10.5194/hess-11-1633-2007>
- Mora, C., & Vieira, G. (2020). The climate of portugal. In G. Vieira, J. L. Zêzere & C. Mora (Cur.), *Landscapes and landforms of portugal* (pp. 33–46). Springer International Publishing. [https://doi.org/10.1007/978-3-319-03641-0\\_2](https://doi.org/10.1007/978-3-319-03641-0_2)
- Santos-Alamillos, F. J., Pozo-Vázquez, D., Ruiz-Arias, J. A., Lara-Fanego, V., & Tovar-Pescador, J. (2012). Analysis of Spatiotemporal Balancing between Wind and Solar Energy Resources in the Southern Iberian Peninsula [Publisher: American Meteorological Society Section: Journal of Applied Meteorology and Climatology]. *Journal of Applied Meteorology and Climatology*, 51(11), 2005–2024. <https://doi.org/10.1175/JAMC-D-11-0189.1>
- APREN - Production*. (2023, marzo 23). Recuperato marzo 23, 2023, da <https://www.apren.pt/en/renewable-energies/production>
- e2p - endogenous energies of Portugal*. (2023, marzo 17). Recuperato marzo 17, 2023, da <http://e2p.inegi.up.pt/#Tec3>
- El-Ahmar, M. H., El-Sayed, A.-H. M., & Hemeida, A. M. (2017). Evaluation of factors affecting wind turbine output power. *2017 Nineteenth International Middle East Power Systems Conference (MEPCON)*, 1471–1476. <https://doi.org/10.1109/MEPCON.2017.8301377>

- Chikate, B. V. (2015). The factors affecting the performance of solar cell. *International Journal of Computer Applications*.
- Box, G. E. P. (1970). *Time series analysis; forecasting and control*. San Francisco : Holden-Day.
- Tsay, R. S. (1984). Regression Models with Time Series Errors [Publisher: Taylor & Francis \_eprint: <https://www.tandfonline.com/doi/pdf/10.1080/01621459.1984.10477073>]. *Journal of the American Statistical Association*, 79(385), 118–124. <https://doi.org/10.1080/01621459.1984.10477073>
- Box, G. E. P., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2015, maggio 29). *Time series analysis: Forecasting and control* [Google-Books-ID: rNt5CgAAQBAJ]. John Wiley & Sons.
- Brockwell, P. J., & Davis, R. A. (2009, maggio 13). *Time series: Theory and methods* [Google-Books-ID: TVIpBgAAQBAJ]. Springer Science & Business Media.
- Liu, D. C., & Nocedal, J. (1989). On the limited memory BFGS method for large scale optimization. *Mathematical Programming*, 45(1), 503–528. <https://doi.org/10.1007/BF01589116>
- Taylor, S. J., & Letham, B. (2017, settembre 27). *Forecasting at scale* (e3190v2) [ISSN: 2167-9843]. PeerJ Inc. <https://doi.org/10.7287/peerj.preprints.3190v2>
- Triebe, O., Laptev, N., & Rajagopal, R. (2019, novembre 27). AR-Net: A simple Auto-Regressive Neural Network for time-series. <https://doi.org/10.48550/arXiv.1911.12436>
- Comment: Building a bridge between traditional statistical time-series models and deep-learning models. Main Topics: Time-Series, Auto-Regression, Neural Networks, Sparsity, Long-Range Dependencies
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning* [[\url{http://www.deeplearningbook.org}](http://www.deeplearningbook.org)] MIT Press.
- Lipton, Z. C., Berkowitz, J., & Elkan, C. (2015, ottobre 17). A Critical Review of Recurrent Neural Networks for Sequence Learning. <https://doi.org/10.48550/arXiv.1506.00019>

- Werbos, P. (1990). Backpropagation through time: what it does and how to do it [Conference Name: Proceedings of the IEEE]. *Proceedings of the IEEE*, 78(10), 1550–1560. <https://doi.org/10.1109/5.58337>
- Jordan, M. I. (1986, maggio 1). *Serial order: a parallel distributed processing approach. Technical report, June 1985-March 1986* (AD-A-173989/5/XAB; ICS-8604). California Univ., San Diego, La Jolla (USA). Inst. for Cognitive Science.
- Elman, J. L. (1990). Finding structure in time [eprint: [https://onlinelibrary.wiley.com/doi/pdf/10.1207/s15516709cog1402\\_1](https://onlinelibrary.wiley.com/doi/pdf/10.1207/s15516709cog1402_1)]. *Cognitive Science*, 14(2), 179–211. [https://doi.org/10.1207/s15516709cog1402\\_1](https://doi.org/10.1207/s15516709cog1402_1)
- Klambauer, G., Unterthiner, T., Mayr, A., & Hochreiter, S. (2017, settembre 7). Self-Normalizing Neural Networks. <https://doi.org/10.48550/arXiv.1706.02515>  
Comment: 9 pages (+ 93 pages appendix)
- Clevert, D.-A., Unterthiner, T., & Hochreiter, S. (2016, febbraio 22). Fast and Accurate Deep Network Learning by Exponential Linear Units (ELUs). <https://doi.org/10.48550/arXiv.1511.07289>  
Comment: Published as a conference paper at ICLR 2016
- Glorot, X., & Bengio, Y. (2010). Understanding the difficulty of training deep feedforward neural networks [ISSN: 1938-7228]. *Proceedings of the Thirteenth International Conference on Artificial Intelligence and Statistics*, 249–256.
- He, K., Zhang, X., Ren, S., & Sun, J. (2015, febbraio 6). Delving Deep into Rectifiers: Surpassing Human-Level Performance on ImageNet Classification. <https://doi.org/10.48550/arXiv.1502.01852>
- Dauphin, Y. N., Pascanu, R., Gulcehre, C., Cho, K., Ganguli, S., & Bengio, Y. (2014). Identifying and attacking the saddle point problem in high-dimensional non-convex optimization. *Advances in Neural Information Processing Systems*, 27.
- Gers, F. A., Schmidhuber, J., & Cummins, F. (2000). Learning to Forget: Continual Prediction with LSTM. *Neural Computation*, 12(10), 2451–2471. <https://doi.org/10.1162/089976600300015015>
- Cho, K., van Merriënboer, B., Bahdanau, D., & Bengio, Y. (2014, ottobre 7). On the Properties of Neural Machine Translation: Encoder-Decoder Approaches. <https://doi.org/10.48550/arXiv.1409.1259>

Comment: Eighth Workshop on Syntax, Semantics and Structure in Statistical Translation (SSST-8)

Chung, J., Gulcehre, C., Cho, K., & Bengio, Y. (2014, dicembre 11). Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling. <https://doi.org/10.48550/arXiv.1412.3555>

Comment: Presented in NIPS 2014 Deep Learning and Representation Learning Workshop

Dickey, D., & Fuller, W. (1979). Distribution of the Estimators for Autoregressive Time Series With a Unit Root. *JASA. Journal of the American Statistical Association*, 74. <https://doi.org/10.2307/2286348>

Akaike, H. (1998). Information theory and an extension of the maximum likelihood principle. In E. Parzen, K. Tanabe & G. Kitagawa (Cur.), *Selected papers of hirotugu akaike* (pp. 199–213). Springer. [https://doi.org/10.1007/978-1-4612-1694-0\\_15](https://doi.org/10.1007/978-1-4612-1694-0_15)

Sola, J., & Sevilla, J. (1997). Importance of input data normalization for the application of neural networks to complex industrial problems [Conference Name: IEEE Transactions on Nuclear Science]. *IEEE Transactions on Nuclear Science*, 44(3), 1464–1468. <https://doi.org/10.1109/23.589532>

Kingma, D. P., & Ba, J. (2017, gennaio 29). Adam: A Method for Stochastic Optimization. <https://doi.org/10.48550/arXiv.1412.6980>

Comment: Published as a conference paper at the 3rd International Conference for Learning Representations, San Diego, 2015

Lokhov, A. (2011). Load-following with nuclear power plants. (29).

Ben Taieb, S., Bontempi, G., Atiya, A. F., & Sorjamaa, A. (2012). A review and comparison of strategies for multi-step ahead time series forecasting based on the NN5 forecasting competition. *Expert Systems with Applications*, 39(8), 7067–7083. <https://doi.org/10.1016/j.eswa.2012.01.039>

Benitez, J., Castro, J., & Requena, I. (1997). Are artificial neural networks black boxes? [Conference Name: IEEE Transactions on Neural Networks]. *IEEE Transactions on Neural Networks*, 8(5), 1156–1164. <https://doi.org/10.1109/72.623216>