



Agenzia nazionale per le nuove tecnologie,
l'energia e lo sviluppo economico sostenibile



MINISTERO DELLO SVILUPPO ECONOMICO



Ricerca di Sistema elettrico

Reti neurali per la predizione dell'assorbimento elettrico di edifici e della produzione di impianti fotovoltaici

A. Laudani, V. Lucaferri, M. Radicioni, F. Riganti Fulginei



Report RdS/PTR(2020)/012

RETI NEURALI PER LA PREDIZIONE DELL'ASSORBIMENTO ELETTRICO DI EDIFICI E DELLA PRODUZIONE DI IMPIANTI FOTOVOLTAICI

Laudani, V. Lucaferri, M. Radicioni, F. Riganti Fulginei
Univ. RomaTRE, Dipartimento di Ingegneria

Aprile 2021

Report Ricerca di Sistema Elettrico

Accordo di Programma Ministero dello Sviluppo Economico - ENEA

Piano Triennale di Realizzazione 2019-2021 - II annualità

Obiettivo: Tecnologie

Progetto: Tecnologie per la penetrazione efficiente del vettore elettrico negli usi finali

Work package: Local Energy District

Linea di attività: LA1.16 - Implementazione di algoritmi basati su Reti Neurali Artificiali per la previsione della produzione fotovoltaica e del carico elettrico di edifici

Responsabile del Progetto: Claudia Meloni, ENEA

Responsabile del Work package: Claudia Meloni, ENEA

Il presente documento descrive le attività di ricerca svolte all'interno dell'Accordo di collaborazione "Sviluppo di algoritmi, soluzioni tecnologiche ed informatiche per gli edifici esistenti e di nuova generazione"

Responsabile scientifico ENEA: Francesco De Lia

Responsabile scientifico: Antonino Laudani e Francesco Riganti Fulginei

Ringraziamenti

Si ringraziano Riccardo Schioppo per la realizzazione dell'impianto, Roberto Lo Presti per la progettazione del software, Irena Balog e Giampaolo Caputo per i dati forniti sulle previsioni meteo.

Indice

SOMMARIO	4
1 INTRODUZIONE	5
2 DESCRIZIONE DELLO SMART BUILDING F40 E DELL'IMPIANTO FOTOVOLTAICO	6
3 ANALISI DEI DATI	7
3.1 PREMessa	7
3.2 SELEZIONE DEL SET DI DATI PER L'APPRENDIMENTO	7
4 RETE NEURALE PER LA PREVISIONE DELLA POTENZA FOTOVOLTAICA GENERATA.....	10
4.1 METODOLOGIA	10
4.2 SVILUPPO DEL MODELLO NEURALE	12
5 METODI PROPOSTI PER RISOLVERE IL PROBLEMA DELL'OMBREGGIAMENTO DEL CAMPO FOTOVOLTAICO	15
5.1 PROBLEMA DELL'OMBREGGIAMENTO DEL CAMPO FOTOVOLTAICO	15
5.2 IMPLEMENTAZIONE DI METODI PER L'ADDESTRAMENTO DELLA RETE NEURALE	18
5.3 METODO 1.....	18
5.4 METODO 2.....	21
5.5 METODO 3.....	22
5.6 PREVISIONI A 24H CON DATI METEO	26
5.6.1 <i>Previsione di radiazione solare</i>	26
5.6.2 <i>Modello WRF-ARW</i>	27
5.7 RISULTATI E CONFRONTO TRA METODI	28
5.7.1 <i>Applicazione dei metodi di previsione della potenza</i>	29
6 RETE NEURALE PER LA PREVISIONE DEL CARICO ELETTRICO	40
6.1 CARATTERISTICHE DEI CARICHI	40
6.2 METODOLOGIA	51
6.3 SVILUPPO DEL MODELLO NEURALE	52
6.4 RISULTATI	52
7 CONCLUSIONI.....	57
8 RIFERIMENTI BIBLIOGRAFICI	57
9 ABBREVIAZIONI ED ACRONIMI	57

Sommario

L'obiettivo della linea di attività in esame è lo sviluppo di metodi basati su tecniche di Intelligenza Artificiale (AI, Artificial Intelligence) per la previsione dell'energia generata da impianti fotovoltaici e per la stima del fabbisogno energetico di Smart Buildings di seconda generazione. Le tecniche sono state applicate al Dimostratore dell'edificio F40 del CR ENEA di Casaccia e saranno estese anche ad altri Dimostratori dell'ENEA. Per ulteriori dettagli circa la progettazione del Dimostratore F40 si veda il Report RdS/PTR2019/004, [1].

È stato scelto di implementare due tipologie di Rete Neurale Artificiale (ANNs, Artificial Neural Networks), una per la previsione della potenza elettrica prodotta dall'impianto fotovoltaico da 18 kW installato sulla copertura dell'edificio F40 ed una per la previsione del carico elettrico del medesimo edificio. Entrambe le previsioni sono effettuate a 24 ore. L'attività risulta, pertanto, suddivisa in due temi principali:

- Un primo filone di ricerca ha riguardato la stima della produzione energetica da fotovoltaico. In questo frangente è stato rilevante un preliminare studio dei dati di impianto e meteorologici disponibili al fine di costituire un opportuno set di dati per l'addestramento della rete, anche noto come *training set*. Successivamente, si sono studiate le varie architetture di reti neurali disponibili e si è selezionata la migliore per l'applicazione in esame.
- Il secondo filone, invece, è stato incentrato sulla selezione di ANN che fossero in grado di fornire una buona previsione a 24 ore dei carichi elettrici di edificio. Anche in questo caso, è stato necessario analizzare varie tipologie di reti per permettere il raggiungimento di performance soddisfacenti. Le reti implementate sono state poi testate su varie tipologie di carichi e su ciascuna delle tre fasi del sistema elettrico.

Entrambe le reti hanno mostrato ottimi risultati con errori che si mantengono intorno al 5% nella previsione di potenza generata e al di sotto del 10% in quella di potenza richiesta dai carichi.

1 Introduzione

Nell'ambito dell'accordo di programma Mise-ENEA, per il Piano Triennale di Realizzazione 2019-2021 ed in particolare dell'attività LA16 del progetto, è prevista l'implementazione di strategie intelligenti per la stima della potenza prodotta dall'impianto fotovoltaico dell'edificio F40 e del suo fabbisogno energetico giornaliero.

Fra le tecniche di Intelligenza Artificiale presenti nella letteratura scientifica, le ANN rivestono un ruolo fondamentale e, pertanto, sono state scelte ed utilizzate nel presente lavoro. Le ANN sono algoritmi matematici ispirati al funzionamento del sistema nervoso dei vertebrati; come tali, le reti sono in grado di "imparare" dall'esperienza secondo un processo noto come *addestramento* o *training* e di generalizzare gli insegnamenti acquisiti anche nel caso di stimoli, o input, cui non erano state sottoposte nel processo di addestramento. Nel processo di addestramento alla rete sono presentati un set di dati di ingresso ed un set con i corrispondenti dati di uscita; queste coppie input-output fungono da esempi per la rete che, opportunamente addestrata, in una fase successiva nota come fase di test sarà in grado di fornire ragionevoli output anche in risposta a nuovi ingressi. Una rete propriamente addestrata avrà raggiunto la capacità di generalizzazione e sarà robusta anche nel caso di set di ingresso rumorosi.

Come anticipato, il lavoro può considerarsi costituito da due argomenti differenti, ma strettamente connessi tra di loro. Da una parte, si ha la necessità di produrre accurate stime di potenza fotovoltaica prodotta per la giornata a venire; in quest'ambito è estremamente importante la scelta di un opportuno training set in quanto è uno degli aspetti fondamentali che influiscono sulle prestazioni dell'algoritmo. Successivamente, scelta l'architettura ottimale della rete, i parametri di progetto sono stati adattati al caso di studio per permettere all'algoritmo di divenire più performante. D'altra parte, si è implementata un'architettura ad hoc che fosse in grado di fornire una buona stima del carico elettrico di edificio.

La possibilità di poter disporre di queste due previsioni costituisce uno step fondamentale nello sviluppo di soluzioni tecnologiche che possano permettere una gestione intelligente dell'energia da fonti rinnovabili.

La stima dell'energia prodotta da fotovoltaico e quella dei fabbisogni energetici rappresentano, infatti, due aspetti che lavorano in modo sinergico tra di loro per permettere una gestione consapevole e flessibile delle risorse elettriche che consenta l'inserimento nel mercato dell'energia elettrica. Il lavoro qui presentato è da intendersi come un tassello fondamentale per lo sviluppo di metodi per il controllo e la gestione dei flussi di potenza e lo scambio intelligente di energia con la rete, così come previsto per la successiva attività LA17.

2 Descrizione dello Smart Building F40 e dell'impianto fotovoltaico

Nel caso in esame, i dati utilizzati per lo sviluppo della rete neurale si riferiscono al Dimostratore dell'edificio F40 del centro ricerche ENEA di Casaccia, uno Smart Building di seconda generazione che include impianti di produzione ed accumulo oltre a sistemi di controllo e management dei flussi di energia che consentono la gestione da remoto di tutti i dispositivi. L'impianto fotovoltaico in esame, installato sulla copertura dell'edificio F40, ha una potenza di picco di 18 kW circa e un sistema di accumulo al Litio da 12 kWh. Come brevemente anticipato, l'impianto è provvisto di un sistema di monitoraggio intelligente che consente di acquisire le grandezze fisiche ed elettriche relative al suo funzionamento. Inoltre, i carichi elettrici dell'edificio sono acquisiti attraverso appositi sensori dal Building Energy Management System (BEMS). Il sistema di monitoraggio è periodicamente interrogato dall'Energy Management System (EMS) che, attraverso il protocollo ModBus-TCP, si occupa dello scambio di flussi di potenza tra sistema di storage, impianto fotovoltaico e carichi utente attuando ogni volta una tra le strategie di gestione implementate. L'impianto è costituito da 56 moduli fotovoltaici al silicio cristallino installati sulla copertura dell'edificio F40. L'impianto è collegato in parallelo alla rete BT del Centro ed in particolare al Quadro Elettrico Generale dell'edificio F40. Le apparecchiature di potenza, così come quelle di trasmissione dati e il sistema di SMART Metering, sono collocate dentro una cabina elettrica appositamente realizzata per il Dimostratore.

Il generatore fotovoltaico da 18,2 kWp è costituito da 6 stringhe indipendenti (4 di esse sono formate da 9 moduli e 2 da 10 moduli) collegate secondo la configurazione serie (S). Le stringhe da 9 e 10 moduli hanno, rispettivamente, potenza nominale di 3,25 kW e 2,925 kW; ognuno dei moduli ha potenza nominale di 325 W.

Di seguito vengono riportate le caratteristiche del generatore fotovoltaico e dei suoi componenti principali, ovvero stringhe e moduli:

Tabella 1. Caratteristiche del generatore fotovoltaico LG Neon2 325 N1C-A5 in Silicio monocristallino (c-Si).

Potenza nominale	18,2 kW
Numero di moduli	56
Numero di stringhe	6
Inclinazione (tilt)	15°
Tensione a circuito aperto @STC (Voc)	408 V (stringhe da 10) / 367,2 V (stringhe da 9)
Tensione alla massima potenza @STC (Vm)	333 V (stringhe da 10) / 299,7 V (stringhe da 9)
Corrente di corto circuito @STC (Isc)	10,41 A
Corrente alla massima potenza @STC (Im)	9,77 A

Tabella 2. Caratteristiche delle stringhe.

Numero di moduli fotovoltaici in serie	10/9
Potenza nominale (Pnom)	3,25kW (stringhe da 10) / 2,925kW (stringhe da 9)
Tensione a circuito aperto (Voc)	408 V (stringhe da 10) / 367,2 (stringhe da 9)
Tensione alla massima potenza @STC (Vm)	333 V (stringhe da 10) / 299,7 (stringhe da 9)
Corrente di corto circuito (Isc)	10,41 A
Corrente alla massima potenza (Im)	9,77 A

Tabella 3. Caratteristiche dei moduli.

Potenza nominale (Pnom)	325W
Tensione a circuito aperto (Voc)	40,8 V
Tensione alla massima potenza (Vm)	33,3 V
Corrente di corto circuito (Isc)	10,41 A
Corrente alla massima potenza (Im)	9,77 A

L'impianto è, inoltre, dotato di appositi sensori per permettere l'acquisizione delle grandezze meteo: si tratta della temperatura ambiente e della temperatura dei moduli, dell'umidità relativa e delle irradiazioni misurate

sul piano orizzontale e sul piano dei moduli. Tali grandezze sono acquisite con passo temporale di 15 secondi e registrate ogni 24 ore su un file giornaliero salvato sul NAS d'impianto.

3 Analisi dei dati

3.1 Premessa

La selezione di un adeguato set di dati di training è l'aspetto più rilevante nell'implementazione di reti neurali artificiali poiché tale scelta influenza la performance e la convergenza della rete. Prima dell'implementazione della rete neurale, la letteratura suggerisce un'analisi di tutti i potenziali dati di input raccolti in un periodo di tempo sufficientemente esteso al fine di identificare quali variabili siano più rilevanti nel processo di apprendimento; un'analisi accurata delle variabili disponibili consentirà di selezionare fra di esse quelle che costituiranno i dati di ingresso necessari alla rete.

3.2 Selezione del set di dati per l'apprendimento

Come anticipato, i file automaticamente generati e salvati sul NAS a fine giornata raccolgono dati con cadenza di 15 secondi e sono, dunque, formati da 5760 campioni. L'impianto è in funzione da Dicembre 2019. Nell'applicazione in esame, è stato scelto di effettuare medie quartorarie dei dati raccolti, ottenendo file giornalieri di 96 campioni.

L'analisi dei dati è stata effettuata sulle seguenti grandezze:

- potenza fotovoltaica generata ($P_{A\,dc}$)
- irradianza solare sul piano orizzontale (Global Horizontal Irradiance, GHI)
- temperatura ambiente (Air Temperature, T_{air})
- coefficiente di umidità relativo dell'aria (Relative Humidity, RH)

L'osservazione dell'andamento delle grandezze nell'arco dell'anno ha suggerito di effettuare un'analisi stagionale dei dati al fine di individuare tutti i possibili scenari. Come sarà approfondito nel seguito, si evidenzia un forte livello di associazione tra irradianza solare e potenza prodotta, ovvero è visibile una forte relazione tra le due grandezze per quanto riguarda la loro forma d'onda; di conseguenza, la forma d'onda della potenza fotovoltaica giornaliera può essere considerata un indicatore della variabilità dell'irradianza solare nell'arco della giornata.

In Figura 1 è presa a campione una settimana per ogni stagione e sono mostrati gli andamenti stagionali delle potenze prodotte; si può notare che inverno ed estate (rispettivamente in alto a sinistra ed a destra) sono caratterizzate da giornate di forma sufficientemente regolare mentre in autunno e primavera (in basso, sinistra e destra) non è possibile identificare un andamento noto.




Figura 1. Andamenti stagionali della potenza fotovoltaica prodotta: in alto a sinistra e a destra si trovano due set di dati che fanno riferimento, rispettivamente, ad inverno ed estate; in basso a sinistra e a destra i dati relativi ad autunno e primavera, rispettivamente.

In Tabella 4 P_{max} , P_{mean} , G_{max} e T_{max} indicano, rispettivamente, il valore massimo ed il valore medio della potenza prodotta, il massimo di GHI e di T_{air} ; si noti che i più alti valori di potenza, e quindi di irradianza, si registrano nel periodo primaverile, mentre i valori medi sono più alti in estate: ciò a dimostrazione delle forti fluttuazioni dei parametri in primavera.

Tabella 4. Dati impianto fotovoltaico in riferimento ai periodi di Fig. 1.

Stagione	P_{max} [W]	P_{mean} [W]	G_{max} [W/m ²]	T_{max} [°C]
Primavera	4912.4	872.4	1237.0	21.7
Estate	3401.8	1101.7	992.5	35.1
Autunno	3538.4	259.9	578.6	18.6
Inverno	4256.2	956.9	715.6	16.0

Ciò si può spiegare con l'aumento di temperatura sui moduli in estate che incrementa le perdite per effetto Joule e riduce l'output in potenza dell'impianto. Queste osservazioni hanno evidenziato l'importanza di una distinzione stagionale dei dati per un miglioramento delle performance della rete.

Inoltre, i parametri meteorologici hanno un profondo impatto sulla produzione di energia fotovoltaica e possono differire da una posizione geografica all'altra.

Il legame tra parametri meteorologici e potenza fotovoltaica è analizzato sulla base della correlazione fra gli uni e l'altra; in particolare la correlazione, ovvero il grado di associazione tra le grandezze in esame, varia se misurata in aree geografiche diverse. L'analisi di correlazione riveste un ruolo fondamentale nel caso in esame in quanto la precisione di un modello di previsione è fortemente legata al livello di associazione tra variabili di input e di output.

In letteratura sono presenti due metodi principali per stimare la correlazione tra due variabili. Il coefficiente di correlazione di Pearson viene generalmente utilizzato per valutare relazioni lineari tra variabili, mentre l'analisi di correlazione di Spearman valuta il rapporto tra due variabili che cambiano insieme non necessariamente in maniera proporzionale. Per il nostro scopo, sono stati scelti i coefficienti di correlazione di Pearson, più indicati nel caso di dati grezzi e per una migliore riproducibilità del lavoro. I coefficienti di

Pearson consentono di misurare il livello di associazione tra due grandezze continue e si basano sul metodo della covarianza secondo la formula:

$$r_{x,y} = \frac{\sum_{i=1}^n (x_i - \bar{x}) (y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}}$$

Nella formula: n è il numero di campioni, x_i e y_i sono i singoli campioni relativi alle variabili x ed y , $\bar{x} = \frac{\sum_{i=1}^n x_i}{n}$ rappresenta il valore medio della variabile x ; lo stesso dicasi per $\bar{y}$.

L'analisi di Pearson fornisce informazioni sia sull'entità, sia sulla direzione dell'associazione. Il coefficiente di Pearson, $r_{x,y}$, può variare nel range $[-1, +1]$ dove un valore assoluto inferiore a 0.5 indica scarsa associazione mentre uno prossimo all'unità evidenzia forte correlazione.

Le nostre analisi hanno confermato quanto evidenziato in letteratura, ovvero una forte dipendenza statistica tra irradianza solare e potenza prodotta, soprattutto nel caso di giornate molto soleggiate.

I risultati sono riportati nell'istogramma di *Figura 2* e si riferiscono a variabili mediate su 30 giorni.




Figura 2. Coefficienti di Pearson calcolati tra la potenza prodotta e le variabili: irradianza, umidità e temperatura dell'aria in un lasso temporale di 30 giorni.

Diversamente, in *Figura 3* i coefficienti di Pearson sono calcolati per la variabile irradianza, grafico a sinistra, e per la variabile temperatura, grafico a destra; i grafici a torta rappresentano la percentuale di coefficienti che nel periodo considerato assumono valori in un determinato range.

In definitiva, si può affermare che le variabili più fortemente correlate alla grandezza di riferimento potenza prodotta sono l'irradianza solare e la temperatura dell'aria.




Figura 3. Coefficienti di correlazione di Pearson, r , per la variabile irradianza, a sinistra, e per la temperatura dell'aria, a destra, calcolati in un periodo di 30 giorni.

4 Rete neurale per la previsione della potenza fotovoltaica generata

L'obiettivo della rete neurale presentata è la previsione a 24 ore della potenza fotovoltaica prodotta dall'impianto in esame. La rete neurale proposta fornisce una previsione giornaliera della potenza prodotta ma, essendo il set di dati utilizzato per il training della rete relativo ad un certo arco temporale, è stato necessario inserire un'indicazione temporale: perciò, è stata aggiunta un'ulteriore variabile a quelle già menzionate che fornisce una mappatura sinusoidale del tempo a passo di 1 minuto.

Sebbene nel training set potrebbero essere considerate ulteriori variabili, ciò complicherebbe eccessivamente l'architettura della rete; perciò, alla luce dei risultati che saranno illustrati nel seguito, si è optato per una struttura più snella della rete dato che la maggiore dimensione della matrice di ingresso aggiungerebbe complessità alla rete senza un effettivo miglioramento delle prestazioni della stessa. Questo aspetto sarà discusso successivamente e saranno presentati alcuni confronti tra la nostra rete ed altre con differenti matrici di training.

4.1 Metodologia

La letteratura scientifica sottolinea l'ampio uso di Reti Neurali Artificiali (Artificial Neural Networks, ANN) nelle applicazioni di previsione grazie alla loro capacità di adattamento e generalizzazione; trovano una vasta applicazione nel campo della previsione di potenza prodotta da impianti fotovoltaici.

La nota rete neurale di tipo Feed Forward (FF) è in grado di apprendere prontamente relazioni lineari e non lineari tra dati di input e di output.

Grazie alla sua architettura semplice, è in grado di ottenere buone prestazioni con bassi costi di calcolo. Queste caratteristiche la rendono ampiamente utilizzata anche nella previsione di serie temporali. D'altra parte, un'altra tipologia di reti, le reti ricorrenti, sono in grado in alcuni casi di offrire prestazioni migliori grazie al riutilizzo di input e/o output passati che sono successivamente reiniettati nella rete. Una rete di questo tipo è generalmente più performante nella determinazione di modelli tempo dipendenti. Perciò, nel caso in esame l'architettura della rete FF è stata modificata aggiungendo un feedback dinamico: ogni neurone dello strato nascosto ha la capacità di elaborare valori precedenti insieme a nuovi segnali di input. In questo modo, la rete neurale è in grado di apprendere dipendenze temporali: nel nostro caso le relazioni tempo-dipendenti sono introdotte dalla variabilità delle condizioni meteorologiche.




Figura 4. Architettura rete neurale dinamica.

Il metodo proposto è implementato in ambiente Matlab che ha permesso di programmare la rete neurale attraverso uno strumento potente e performante.

L'architettura di una generica Rete Neurale Artificiale è costituita da neuroni organizzati in diversi strati: strato di ingresso, strato nascosto e strato di uscita; ognuno di essi è composto da un insieme di neuroni

artificiali collegati tra loro tramite pesi sinaptici che vengono aggiustati via via nel corso del processo di apprendimento.




Figura 5. Struttura neurone artificiale.

L'unità base è il neurone artificiale, mostrato nella Figura 5, che può essere espresso matematicamente come:

$$u_k = \sum_{j=1}^m w_{k,j} x_j$$

$$y_k = \varphi(u_k + b_k)$$

dove x_j sono gli ingressi di un generico neurone k che sono moltiplicati per il rispettivo peso $w_{k,j}$ e poi sommati. Alla somma viene aggiunto un bias, b_k , e viene poi applicata alla funzione di attivazione φ .

La capacità della rete neurale di fornire soluzioni ragionevoli è ottenuta mediante un processo di allenamento che consiste nel regolare iterativamente i valori dei pesi sinaptici al fine di minimizzare un errore definito come la differenza tra previsioni del modello e le reali osservazioni. Durante il processo di addestramento (o di training), le derivate dell'errore sono retropropagate in ogni strato, a partire da quello di uscita fino a risalire a quello di ingresso, al fine di modificare i parametri.

Uno degli algoritmi di apprendimento più utilizzati è il Levenberg-Marquardt che aggiorna i pesi come segue:

$$w_{k+1} = w_k - (J_k^T J_k + \mu I)^{-1} J_k e_k$$

l'errore e_k è la differenza tra l'uscita desiderata e quella effettiva e J è la matrice Jacobiana del vettore di errore, e_k . Il parametro μ viene aumentato o diminuito ad ogni passo. Questo processo continua fintanto che non sia ottenuta l'uscita desiderata o che si raggiunga un criterio di arresto, come ad esempio una soglia di errore o il numero massimo di iterazioni. Con il termine iterazione o epoca si intende ogni ciclo completo di presentazione di tutti gli input alla rete e di calcolo dell'uscita.

Un indice della bontà del processo di training è il raggiungimento della generalizzazione, ovvero la capacità della rete di fornire risultati sufficientemente accurati anche in risposta ad input non presentati durante il processo di apprendimento. Se tali obiettivi sono raggiunti, la rete sarà robusta anche nel caso di dati rumorosi.

La questione principale nell'implementazione di una qualsivoglia rete neurale è la scelta dei principali parametri: numero di neuroni, numero di strati, eventuali ritardi ecc... Poiché non esiste una procedura esatta per risolvere questo problema, l'architettura della rete è selezionata sulla base di un processo per tentativi ed errori.

La scelta di un opportuno ritardo richiede una dettagliata analisi di stabilità per permettere alla rete di raggiungere una condizione di stabilità globale. Altro importante parametro è il numero di neuroni anch'esso scelto sulla base di diverse prove che permettono di minimizzare l'errore ed ottenere l'architettura finale.

La misurazione dell'accuratezza di qualsiasi modello di previsione è eseguito per mezzo di errori di prestazione standardizzati, come ad esempio l'errore quadratico medio (Mean Square Error, MSE), la radice

dell'errore quadratico medio (Root Mean Square Error, RMSE), l'errore medio assoluto (Mean Absolute Error, MAE), errore percentuale medio assoluto (Mean Absolute Percentage Error, MAPE), errore percentuale medio assoluto ponderato (Weighted Mean Absolute Percentage Error WMAPE. Nella nostra analisi vengono valutati RMSE e WMAPE in modo da semplificare il confronto con altri modelli neurali presenti in letteratura.

4.2 Sviluppo del modello neurale

Il modello neurale presentato è stato, in una prima fase, applicato ad un impianto di prova denominato F50, distante circa 500 metri in linea d'area dall'edificio F40, come mostrato in dettaglio in [2]. Alla luce dei risultati ottenuti il modello è stato, successivamente, esteso all'impianto installato sulla copertura dell'F40 dove è stato ulteriormente migliorato per far fronte alle problematiche di ombreggiamento sistematico di cui si parlerà nel Capitolo 5.

Nella presente applicazione, sono state individuate tre condizioni rilevanti ai fini dell'implementazione della rete: la variazione del numero di neuroni, la dimensione del training set e la differenza tra un'architettura statica ed una dinamica. Facendo riferimento all'analisi di correlazione, vengono condotti ulteriori studi per selezionare la migliore combinazione di dati disponibili e la dimensione corretta del training set. Quindi, per sviluppare un modello accurato, sono analizzati i seguenti casi di studio:

- *Caso n. 1.* Si effettuano la selezione dell'opportuno set di dati di input in base alla precedente analisi di correlazione analisi e la valutazione dell'adeguata dimensione del training set.
- *Caso n. 2.* Dopo aver selezionato il training set, le capacità della rete sono valutate variando il numero di neuroni in un range definito.
- *Caso n. 3.* Le prestazioni di una rete di tipo statico sono confrontate con quelle di un modello dinamico. Introduciamo un "effetto di memoria" all'architettura statica, dotando la rete di un comportamento dinamico. Come sarà chiarito nel seguito, l'idea è quella di riportare in ingresso alla rete l'ultimo valore di potenza previsto in modo da costruire una sorta di serie temporale; in questo modo è stato possibile beneficiare dei vantaggi delle reti dinamiche senza, però, implementarne una vera e propria, eliminando, dunque, gli aspetti svantaggiosi quali la necessità di grandi risorse computazionali e più complessi processi di apprendimento. Le prestazioni della ANN sono valutate sui profili di potenza della Figura 6; ogni giornata riportata è l'ultima delle stagioni mostrate in Figura 1.




Figura 6. Giornate utilizzate come target della rete neurale.

Caso n. 1. Facendo riferimento alla precedente analisi di correlazione, sono valutate differenti combinazioni di input e per ciascuna di esse sono calcolati RMSE e WMAPE. Per questa analisi, viene scelta un'architettura FF, il numero di neuroni nello strato nascosto è fissato a 10 ed il training set è formato da 20 giorni, un buon compromesso tra la dimensione del training set e la complessità della ANN. Sono analizzate quattro combinazioni di input: ognuna di esse include il vettore sinusoidale del tempo e dell'irradianza poiché il primo è fondamentale per la distinzione delle giornate, il secondo è l'input più correlato con l'output della rete. Si considera quindi una prima combinazione di input, composta dai soli vettori tempo e irradianza. Il WMAPE

ottenuto è di circa il 37,5%. Nella seconda e terza combinazione sono aggiunti ulteriori input, rispettivamente la temperatura e l'umidità dell'aria.

I risultati sperimentali confermano le conclusioni dell'analisi di correlazione riportate in Figura 2.

Infine, l'ultima combinazione include tutte le variabili. Gli ultimi tre set di dati offrono un miglioramento delle prestazioni della rete, ma solamente il secondo set è in grado di determinare un WMAPE al di sotto del 15%. Gli errori ottenuti per ciascun set sono riportati nella Tabella 5 (gli errori riportati sono mediati sulle giornate di Figura 6). Questa analisi ha consentito di individuare i vettori di tempo, irraggiamento e temperatura come gli input più appropriati per la rete.

Tabella 5. RMSE e WMAPE calcolati per diverse combinazioni di ingressi.

Ingressi ANN	RMSE (W)	WMAPE (%)
Tempo+Irradianza	390.12	37.50
Tempo+Irradianza+Temperatura	120.50	14.97
Tempo+Irradianza+Umidità	240.78	21.02
Tempo+Irradianza+Temperatura+Umidità	230.66	19.46

Il secondo passo consiste nel trovare la dimensione corretta del training set ovvero nella scelta del numero di giorni da includere nel set. In particolare, si è scelto di far variare il numero di giorni in un intervallo compreso tra 5 e 30.

In Figura 7 è mostrato il WMAPE per ogni stagione. Vale la pena notare che il WMAPE raggiunge il suo minimo con training set della dimensione di 5 giorni nei periodi estivo ed invernale; per quanto riguarda la primavera e l'autunno, è, invece, necessario un set composto da 30 giorni data la variabilità delle condizioni meteo. Pertanto, le dimensioni del training set possono essere ridotte in estate ed inverno. In definitiva, le dimensioni dei training set possono essere fissate a 480 campioni per ogni vettore di input in estate ed inverno e 2880 in primavera ed autunno.




Figura 7. A sinistra viene riportato l'andamento del WMAPE al variare del numero delle giornate che compongono il training set per inverno ed estate. A destra si trova l'andamento del WMAPE al variare del numero delle giornate che compongono il training set per autunno e primavera.

Caso n. 2. Successivamente alla selezione del training set più appropriato, è necessario un'ulteriore analisi per lo studio dell'influenza del numero di neuroni dello strato nascosto. È stata scelta una rete con un singolo strato nascosto poiché i risultati molto positivi ottenuti portano a prediligere un'architettura più snella a dispetto di un inutile appesantimento della stessa.

Diverse prove sono state condotte variando il numero di unità neurali tra 4 e 22. I risultati ottenuti si riferiscono ad un training set composto da 5 e 30 giorni. In Figura 8 sono riportati gli errori WMAPE ed RMSE mediati rispetto alle quattro stagioni.

È evidente che un training set costituito da 30 giorni permette di raggiungere un errore inferiore in quasi tutti i casi. Inoltre, gli errori sono simili in un intervallo tra 5 e 10 neuroni, come mostrato in Figura 8. Pertanto, questo lavoro propone una strategia automatica in grado di valutare la rete con la migliore performance: ciò è ottenuto tramite un algoritmo che opera fissando gli ingressi della rete, scegliendo la dimensione del training set tra 5 o 30 giorni in base alla stagione e selezionando il numero di neuroni più adatto in base al

caso particolare. Questa procedura riconfigurabile permette di ottenere l'architettura più performante a seconda della particolare stagione.




Figura 8. A sinistra viene riportato l'andamento del WMAPE al variare del numero di neuroni. A destra si trova l'andamento del RMSE al variare del numero di neuroni.

Caso n. 3. La strategia esposta in precedenza mostra buoni risultati per le giornate soleggiate ma, nel caso di condizioni di parziale o totale copertura del cielo non è sempre possibile per la rete raggiungere la generalizzazione.

Per questo, è introdotto nella rete un ritardo temporale, Δt , pari a 15 min fornendo all'architettura FF un comportamento dinamico (D-FFNN, Dynamic Feed-Forward Neural Network): la potenza continua prodotta all'istante $(t - \Delta t)$, ossia $P_{ac}(t - \Delta t)$, è inclusa come quarto ingresso: la Tabella 6 mostra che il WMAPE si riduce notevolmente se si considera questo ulteriore input. In particolare, per l'estate e l'inverno, diminuisce leggermente se si considera un'architettura D-FFNN.

Per quanto riguarda l'autunno e la primavera si verifica, invece, un guadagno significativo: l'errore si riduce oltre il 20%.

Tabella 6. RMSE e WMAPE ottenuti con la rete neurale statica (FFNN) e con quelle dinamica (DFFNN).

	WMAPE (%) FFNN	RMSE (W) DFFNN
Primavera	20.07	14.78
Estate	4.04	3.12
Autunno	21.85	15.63
Inverno	6.89	4.21

Una valutazione degli errori riguardanti le fasi di apprendimento e validazione porta a scegliere una rete di tipo statico o dinamico con un numero di neuroni variabile da 5 a 10 a seconda della particolare giornata. Un riepilogo dell'architettura dinamica ottimale è riportato nella Tabella 7.

Tabella 7. Parametri della rete neurale dinamica (DFFNN).

Parametri ANN	
Ingressi	3 – Tempo, Irradianza, Temperatura
Uscite	1 – Potenza PV
Numero di strati	3 – Ingresso, Nascosto, Uscita
Numero di neuroni nello strato nascosto	5:10
Numero di ritardi	1 – Potenza PV
Funzioni	Logaritmica-sinusoidale, Lineare
Algoritmi di addestramento	Levenberg-Marquardt

5 Metodi proposti per risolvere il problema dell'ombreggiamento del campo fotovoltaico

5.1 *Problema dell'ombreggiamento del campo fotovoltaico*

Nella figura riportata di seguito è mostrato l'impianto fotovoltaico installato sulla copertura dell'edificio F40, precedente descritto. Per chiarezza, è necessario dire che le 6 stringhe che compongono l'impianto sono suddivise in gruppi di 2 stringhe ciascuno andando a costituire 3 array indipendenti l'uno dall'altro ed ognuno di essi è connesso ad un diverso inverter. Gli inverter utilizzati sono inverter monofase ABB REACT-UNO-4.6-TL prodotti da ABB: per questo motivo, per semplicità, i 3 gruppi di stringhe saranno indicati come React1, React2 e React3. Il sensore di irradianza è montato sul React1, come tale il vettore di irradianza che viene misurato ogni giorno tiene conto di eventuali ombre che cadono sul React1 e non tiene conto di eventuali ombre presenti invece sui React2 e React3.

Le ombre sulle stringhe sono determinate da alcune strutture poste sul tetto dell'edificio ed adiacenti all'impianto; a titolo di esempio si vedano Figure 10-11. Gli ombreggiamenti che tali strutture determinano non sono costanti durante tutto l'anno, ma si concentrano nel periodo invernale, indicativamente nell'intervallo di mesi compreso tra Novembre e Febbraio. In particolare, le ombre sono distribuite come spiegato nel seguito:

- React 1: si nota un ombreggiamento durante la mattinata (approssimativamente tra le ore 9 e le 10);
- React 2: le ombre si concentrano a metà giornata e poi nuovamente nel primo pomeriggio;
- React 3: si verifica ombreggiamento solamente nel pomeriggio.




Figura 9. Impianto fotovoltaico installato sulla copertura dell'edificio F40. Il sensore di irradianza è installato solo in prossimità del React1.




Figura 10. Ombreggiamenti durante la giornata del 13/10/2021 sul React1, rispettivamente ore 10 e ore 11.




Figura 11. Ombreggiamenti durante la giornata del 13/10/2021 sui React2 e React3, rispettivamente ore 13 e ore 15.

Nel seguito sono mostrati i profili della potenza generata dai 3 React in diversi giorni dell'anno: si può notare che ogni React risente di un profilo di irradianza diverso. Come evidenziato dall'analisi di correlazione effettuata in precedenza, il profilo di irradianza di un impianto o array fotovoltaico incide sensibilmente sul suo profilo di potenza generata. Ciò è evidente quando sono confrontati il profilo di irradianza e di potenza relativi al React 1. Nelle figure seguenti, il profilo di irradianza del React 1 (l'unico profilo che il sensore è in grado di rilevare) è messo a confronto con i profili di potenza dei React 2 e 3 al fine di provare che i React2 e React3 sono soggetti ad un ombreggiamento diverso dal React 1.

Relativamente al React1, dai due profili in Figura 12 si può notare come sia piranometro che impianto fotovoltaico siano soggetti ad un ombreggiamento che si verifica nelle prime ore del mattino.

Figura 13, invece, nei profili riferiti al React 2 evidenzia come l'ombreggiamento che incide sul piranometro sia diverso da quello che incide sul React2: come anticipato, nel primo si verifica un ombreggiamento nelle prime ore del mattino, mentre sul React2 si ha un ombreggiamento sia a metà giornata che nel pomeriggio. Infine, in Figura 14, si nota, ancora una volta, la differenza nei profili: sul piranometro si hanno, al solito, ombre in mattinata, mentre sul React3 si ha un ombreggiamento solo a fine giornata.




Figura 12. A sinistra, l'irradianza misurata dal piranometro posto in prossimità del React1; a destra, la potenza misurata generata dal React1.




Figura 13. A sinistra, l'irradianza misurata dal piranometro posto in prossimità del React1; a destra, la potenza misurata generata dal React2.




Figura 14. A sinistra, l'irradianza misurata dal piranometro posto in prossimità del React1; a destra, la potenza misurata generata dal React3.

5.2 Implementazione di metodi per l'addestramento della rete neurale

Nel processo di sviluppo di una strategia che fosse in grado di fornire una previsione accurata della potenza generata partendo dai dati d'ingresso di cui si è parlato nei paragrafi precedenti, in un primo momento si è applicato quello che nel seguito sarà chiamato *Metodo 1*; tale metodo consiste nell'addestrare la rete neurale utilizzando l'irradianza misurata dal piranometro posto in prossimità del React1. Nonostante in alcuni periodi dell'anno, questo metodo ha permesso di ottenere una buona previsione di potenza per tutti i tre React, ciò non si è verificato in altri periodi; in particolare, questo metodo può essere particolarmente efficace in periodi nei quali i React non sono soggetti ad ombreggiamenti: in tal caso, non vi sono differenze tra i profili di irradianza dei 3 React e ciò si riflette sulla bontà dei risultati di previsione.

Per risolvere questo problema, si è scelto di implementare altri due metodi: il *Metodo 2* ed il *Metodo 3*, che saranno esposti nel dettaglio, insieme al *Metodo 1*, nei prossimi paragrafi. Ogni metodo prevede l'implementazione di una rete neurale in grado di eseguire una previsione a 24 ore della potenza generata da ogni singolo React, come spiegato in precedenza. La differenza tra i tre metodi risiede nelle matrici di addestramento, in particolare, nel vettore di irradianza.

5.3 Metodo 1

La prima soluzione implementata consiste nell'addestramento di una rete neurale per ogni singolo React, come descritto in precedenza, utilizzando nelle matrici di addestramento il vettore di irradianza con i valori misurati dal piranometro situato in prossimità del React1.

Di seguito è riportato un esempio dei vettori di irradianza e potenza che costituiscono le matrici di addestramento in riferimento alla settimana che 07/11/2020 - 13/11/2020, Figura 15.




Figura 15. In alto, il vettore di irradianza misurata dal piranometro situato in prossimità del React1 dal 07/11/2020 al 13/11/2020. In basso, la potenza misurata generata dal React1 nelle stesse giornate.

Lo stesso vettore di irradianza è stato utilizzato nelle matrici per l'addestramento delle reti neurali necessarie alla previsione della potenza generata dai React2 e React3, Figura 16.




Figura 16. In alto, il vettore di irradianza misurata dal piranometro situato in prossimità del React1 dal 07/11/2020 al 13/11/2020; in basso, la potenza misurata generata dal React2 nelle stesse giornate.

Come descritto nel paragrafo precedente i profili di irradianza riferite al React1 evidenziano ombreggiamenti diversi rispetto a quelli che si verificano sui React2 e React3. Questo risulta evidente nelle giornate particolarmente soleggiate, dove si può osservare che alcuni ombreggiamenti fissi tipici del React1 sono molto diversi da quelli del React2. Questo viene confermato dalle figure successive per il React3.




Figura 17. In alto, il vettore di irradianza misurata dal piranometro situato in prossimità del React1 dal 07/11/2020 al 13/11/2020; in basso, la potenza misurata generata dal React3 nelle stesse giornate.

Nei paragrafi successivi sarà mostrato come questa diversità di ombreggiamento nelle stringhe influisca nelle performance della rete neurale.

5.4 Metodo 2

Nel *Metodo 2*, la rete neurale è stata addestrata per ogni singolo React utilizzando nelle matrici di addestramento il vettore di irradianza con i valori relativi ad una stazione meteo posta sull'impianto F50 presente in Casaccia. Tale stazione meteo dista 500 m in line d'aria dall'impianto F40 e non risulta affetta da ombreggiamenti. Tale piranometro potrebbe essere utilizzato per coprire un'intera area di impianti, purché vicini, evitando così di installare più sensori.

Di seguito è riportato un esempio dei vettori di irradianza e potenza relativi al *Metodo 2*, sempre in riferimento alla settimana che va dal 07/11/2020 al 13/11/2020. Per brevità, si omette il confronto con i profili di potenza presentati nel *Metodo 1*; il profilo di Figura 18, come nel caso del Metodo 1, è da considerarsi valido per tutti e tre i React. Si noti come in giornate perfettamente soleggiate non si abbiano profili di ombreggiamento particolari.




Figura 18. Vettore di irradianza misurata dal piranometro situato in prossimità dell'impianto fotovoltaico dell'edificio F50 in riferimento alla settimana 07/11/2020 - 13/11/2020.

5.5 Metodo 3

Nello sviluppo della terza strategia si è pensato ad un modo per migliorare le performance della rete fornendo dati di ingresso quanto più accurati possibile. A questo scopo si è deciso di ricorrere ad una formulazione matematica dell'irradianza sviluppata in [3] che permette di svincolare l'acquisizione della grandezza irradianza dall'utilizzo di un apposito sensore. Il metodo in esame ha permesso di ricavare i profili di irradianza su ciascuno dei 3 React con i relativi ombreggiamenti e con un altissimo grado di accuratezza. Questo metodo risulta particolarmente vantaggioso non solo perché permette di ottenere profili di irradianza senza ricorrere all'installazione di un apposito piranometro per ogni stringa o gruppo di stringhe, ma anche perché la maggiore accuratezza dei profili di irradianza permette di migliorare notevolmente le performance della rete neurale nella previsione di potenza. Si chiarisce che la possibilità di eliminare l'uso del sensore di irradianza apporta notevoli vantaggi di natura tecnico-economica:

- In primo luogo, il posizionamento di un piranometro su di un modulo con una determinata inclinazione è una procedura complessa: il sensore dovrebbe essere montato su di una struttura rigida perfettamente parallela al dispositivo fotovoltaico;
- In secondo luogo, un piranometro è tutt'altro che uno strumento economico; aldilà del costo del sensore stesso – che supera comunque diverse centinaia di euro per singolo sensore: nel nostro caso ne occorrerebbero tre – è necessario ricordare che un piranometro necessita di calibrazioni periodiche da effettuarsi presso appositi laboratori di testing per mantenerne alta l'accuratezza - come prescritto nelle norme IEC 61724-1:2017.

Si fornisce, qui di seguito, una spiegazione qualitativa della formula di cui sopra. La forma-chiusa per il calcolo dell'irradianza deriva da manipolazioni algebriche della formula della corrente fotogenerata riferita al noto modello a singolo diodo per dispositivi fotovoltaici:

$$i_{pv} = N_p I_{irr} - N_p I_0 \left[\exp \left(\frac{q \left(v_{pv} + \frac{i_{pv} N_s R_s}{N_p} \right)}{N_s n k T} \right) - 1 \right] - \frac{v_{pv} + \frac{i_{pv} N_s R_s}{N_p}}{N_s R_p / N_p}$$

Nella formula è possibile riconoscere alcuni importanti parametri quali la resistenza serie, R_s , la resistenza di shunt, R_p , il fattore d'idealità del diodo, n , la corrente di irraggiamento, I_{irr} , e quella di saturazione del diodo, I_0 : la conoscenza di questi 5 parametri è fondamentale per il calcolo dell'irradianza.




Figura 19. Modello a un diodo.

Le altre informazioni necessarie per utilizzare la formula sono la temperatura ambiente ed il punto operativo del dispositivo fotovoltaico, cioè la corrente e la tensione di esercizio. Inseriti questi dati nella formula, è possibile tracciare un profilo giornaliero dell'irradianza su un qualsivoglia modulo o array fotovoltaico. L'errore quadratico medio della grandezza calcolata rispetto a quella misurata si attesta intorno all'1,5 %, [3]. È stato sviluppato un codice in ambiente Matlab in grado di acquisire il punto di lavoro della stringa a passo di un minuto. Il codice consente di leggere le grandezze tensione e corrente di lavoro della stringa con un passo temporale preimpostato a piacere. L'ambiente di lavoro Matlab ha consentito di implementare una comunicazione di tipo Modbus-TCP con gli inverter dell'impianto e di accedere direttamente ai registri modbus di interesse. I registri di interesse sono mostrati in Figura 20.

Register address [7:1]	Number of registers	Registers content description	Range	Unit	Data type [2:1]	Maximum scan rate (ms)	Notes
INPUT REGISTERS							
INVERTER							
<i>Information</i>							
10XX	2	Inverter - Input 1 - Voltage	-	V	F32	100	
10XX	2	Inverter - Input 1 - Current	-	A	F32	100	
10XX	2	Inverter - Input 1 - Power	-	W	F32	100	
10XX	2	Inverter - Input 2 - Voltage	-	V	F32	100	
10XX	2	Inverter - Input 2 - Current	-	A	F32	100	

Figura 20. Indirizzo dei registri per l'acquisizione di tensione e corrente dagli inverter ABB-React.

A dimostrazione dell'efficacia della formula per il calcolo dell'irradianza, sono stati confrontati i profili di irradianza del React 1 relativi a diverse giornate. I profili calcolati sono confrontati con le misurazioni del piranometro installato vicino al React1. L'errore percentuale è sempre inferiore al 7%, in particolare, è pari al 5.9% per il 17/02, al 5.6% per il 26/02, al 4.2% per il 07/03 ed al 5.5% per l'11/03.




Figura 21. Confronto tra irradianza sul modulo misurata dal piranometro posto sul React1 e irradianza calcolata in forma chiusa per quattro diverse giornate.

Dai risultati ottenuti è evidente che il calcolo dell'irradianza in forma chiusa riesce ad approssimare il profilo d'irradianza misurato con un errore percentuale molto basso sia nel caso di giornate perfettamente soleggiate, sia in giornate con parziale nuvolosità.

Gli ottimi risultati mostrati legittimano l'utilizzo della formula anche per i React 2 e 3, per i quali non è possibile effettuare un confronto diretto con le misurazioni a causa della mancanza di appositi sensori installati su di essi. Tuttavia, i profili calcolati possono essere confrontati con le potenze generate dai React 2 e 3 – si ricordino i risultati dell'analisi di correlazione; per questa comparazione si veda il paragrafo dei risultati.

Il codice per l'acquisizione di tensione e corrente di esercizio dell'impianto è stato lanciato anche per acquisire il punto di lavoro dei React2 e React3. Acquisite queste informazioni, è stato possibile utilizzare i profili di irradianza calcolati per creare le matrici di addestramento per i React2 e React3, in modo da tener conto dei diversi ombreggiamenti per i tre React. Di seguito si riporta una settimana estratta dalle matrici di addestramento per ciascun React.




Figura 22. Vettore di irradianza calcolata in forma chiusa per il React1 in riferimento alla settimana 26/02/2021 - 04/03/2021.




Figura 23. Vettore di irradianza calcolata in forma chiusa per il React2 in riferimento alla settimana 26/02/2021 - 04/03/2021.




Figura 24. Vettore di irradianza calcolata in forma chiusa per il React3 in riferimento alla settimana 26/02/2021 - 04/03/2021.

Si noti come il Metodo 3 sia in grado di rilevare sia giornate perfettamente soleggiate che eventuali ombreggiamenti presenti su ciascuno dei React.

5.6 Previsioni a 24h con dati meteo

Nei paragrafi precedenti si è ampiamente discusso del processo di apprendimento delle reti neurali. Una volta terminato il training della rete, questa è pronta ad essere utilizzata per effettuare la previsione di potenza. L'utilizzo della rete prevede che ad essa sia presentata una matrice relativa al giorno per cui si vuole effettuare la previsione contenente gli stessi vettori delle matrici di training – cioè i vettori tempo, temperatura, irradianza e potenza al quarto d'ora precedente; in risposta a questi input la rete produrrà un output di potenza. A posteriori, sarà possibile valutare la bontà della previsione tramite un confronto con i dati effettivi dell'impianto.

Ovviamente, non potendo disporre dei dati effettivi relativi alla temperatura ed all'irradianza per la giornata ventura, sono state utilizzate come input le previsioni meteorologiche di tali grandezze facendo ricorso al modello WRF-ARW.

5.6.1 Previsione di radiazione solare

In Italia si è assistito negli ultimi anni ad un'espansione esponenziale dell'installazione d'impianti solari ed in particolare di quelli fotovoltaici. Si presentano quindi due necessità: la prima a scala locale, nella quale i proprietari dei singoli impianti ricavano beneficio dal conoscere in anticipo la radiazione solare che potranno "raccogliere" al fine di gestire opportunamente il proprio impianto, oppure per immettere nella rete elettrica l'energia prodotta nei momenti di maggiore remunerazione, alla luce della tariffazione presente sul mercato dell'energia; la seconda necessità è a scala nazionale nella quale il Gestore dell'energia deve amministrare tutte le utenze e quindi deve conoscere in anticipo quali saranno le esigenze della rete nei diversi punti del territorio. Alla luce di questo scenario risulta evidente l'utilità di sviluppare un sistema di previsione della radiazione solare che rappresenta la naturale evoluzione delle previsioni meteorologiche. L'evoluzione che si è verificata nel campo delle previsioni meteorologiche ha consentito di raggiungere un grado di affidabilità

elevato grazie all'enorme sviluppo dei calcolatori. Le previsioni meteorologiche richiedono l'impiego di una rete internazionale di raccolta ed accentrimento di dati misurati al suolo ed in quota su tutta la superficie terrestre, di calcolatori potentissimi che elaborano questi dati trovando la soluzione a complicate equazioni matematiche che simulano il comportamento dell'atmosfera. I dati in ingresso sono costituiti dai valori della temperatura, umidità, vento e pressione. Le elaborazioni restituiscono in uscita grandezze derivate quali la copertura nuvolosa, le precipitazioni ecc.. Tutte le stazioni meteo che effettuano misure al suolo ed in quota sono coordinate dall'Organizzazione Meteorologica Mondiale (WMO).

A livello internazionale esistono vari centri di calcolo dedicati alla meteorologia. In questi centri vengono fatti "girare" modelli, a scala globale, che rappresentano l'atmosfera scomposta in livelli verticali (40-60), fino ad una certa quota (da 50 a 80 Km), ed una risoluzione orizzontale (20-40 Km). Oltre a modelli a scala globale, sono stati sviluppati modelli a scala locale che tengono conto in maniera più dettagliata delle caratteristiche geografiche del suolo al quale si applicano. I modelli a scala globale servono ad inizializzare quelli a scala locale, cioè questi ultimi utilizzano i dati in uscita dei modelli globali come dati iniziali in entrata e come dati ai bordi dell'area specifica considerata.

L'evoluzione delle previsioni del tempo ha quindi portato allo sviluppo di modelli sempre più specializzati tra i quali quelli che prevedono la radiazione solare. Tali modelli possono quindi essere concettualmente rappresentati dallo sviluppo in sequenza di due fasi successive. La prima è la simulazione del moto atmosferico (termodinamica) e dei fenomeni di trasformazione dell'acqua (nubi, precipitazioni...) ottenibili da una catena modellistica prognostica simile a quelle usate per le previsioni del tempo. La seconda è costituita da un modello di trasferimento radiativo che, utilizzando le variabili atmosferiche sulla verticale previste dal primo modello, calcola su ogni punto le varie componenti della radiazione al suolo. Il sistema di previsione della radiazione solare sviluppato in ENEA (modello meteorologico WRF-ARW) nasce dalla necessità di conoscere in anticipo l'energia solare che sarà disponibile nel breve periodo (oggi, domani e dopodomani) al fine di garantire una corretta gestione degli impianti solari per la produzione di energia. L'energia solare è caratterizzata da un'aleatorietà intrinseca e, oltre ad avere interruzioni dovute all'alternanza giorno-notte e a risentire del ciclo stagionale che ne fa variare la disponibilità giornaliera nel corso dell'anno, risente delle condizioni meteorologiche contingenti. Possono verificarsi infatti situazioni nelle quali l'impianto solare è interessato dal passaggio occasionale di nubi che coprono totalmente o in parte il sito dell'impianto in giornate altrimenti soleggiate, oppure possono verificarsi situazioni con giorni di maltempo prolungato durante i quali l'impianto non riceve per lungo tempo energia solare. Per programmare la produzione di energia elettrica e la gestione dell'energia accumulata negli impianti solari, è di fondamentale importanza la stima della produttività dell'impianto nei giorni successivi e quindi della radiazione solare prevista. Non va quindi sottovalutata l'utilità di un uso appropriato delle previsioni di radiazione solare che consentirebbe di risparmiare le spese di acquisto degli apparati di accumulo a volte molto costosi. Infatti, le previsioni debitamente inserite nei programmi di gestione degli impianti solari potrebbero ridurre al minimo indispensabile l'accumulo.

5.6.2 Modello WRF-ARW

Il modello WRF (Weather Research and Forecasting Model), sviluppato e distribuito dal National Center for Atmospheric Research USA, è un sistema di simulazione atmosferica creato per la ricerca e per la previsione meteorologica. Il WRF è, tra i modelli atmosferici, il più utilizzato nel campo della ricerca scientifica; è disponibile gratuitamente ed è efficiente anche per il calcolo parallelo. Esso offre una vasta gamma di applicazioni a diversa scala, dai fenomeni alla microscala (su uno spazio di qualche metro) a quelli alla scala sinottica (su uno spazio di migliaia di chilometri). Si tratta di un modello fluidodinamico completamente comprimibile e non idrostatico in cui vengono conservate le variabili scalari e sono applicati gli schemi di integrazione di Runge-Kutta. La griglia spaziale utilizzata è del tipo Arakawa C-grid.

Le condizioni iniziali e al contorno necessarie per le nostre simulazioni con il modello WRF sono ottenute dai campi del modello globale americano GFS (Environmental Modeling Center, 2003), distribuite su una griglia di

0,25°x0,25°. La dimensione della griglia del modello è 10x10 km dove le simulazioni hanno nella griglia 151x151 punti con il centro del dominio computazionale alla latitudine 41,25 ° e longitudine 13,5 °, che copre la regione d'Italia, Figura 25. Una corsa giornaliera del modello WRF inizializzata dalle 00 UTC con i quattro output giornalieri del modello GFS, fornisce campi previsionali a passo orario per le successive 48 ore sul dominio prescelto. Lo schema di Dudhia viene utilizzato per la parametrizzazione della radiazione solare. In questo studio è stato utilizzato il core Advanced Research WRF-ARW.




Figura 25. Dominio di calcolo del modello WRF-ARW.

5.7 Risultati e confronto tra metodi

Alla luce dei metodi di implementazione della rete sopra illustrati, si riportano i risultati conseguiti con ciascuno di essi.

È necessaria una considerazione preliminare; la bontà nella stima della potenza generata è strettamente legata all'accuratezza delle previsioni meteorologiche utilizzate per la previsione: una rete ben allenata a cui, tuttavia, è passato un set di dati in ingresso con previsioni meteo non precise fornirà, inevitabilmente, una previsione di potenza meno accurata rispetto alla stessa rete alla quale sono fornite previsioni meteo esatte. In Figura 26 è mostrato il confronto tra le previsioni di irradianza fornite dal modello WRF-ARW e le misurazioni del piranometro installato sul React1 per la giornata del 03/03/2021: si può notare un errore di circa il 10 %.




Figura 26. Errore previsione modello WRF-ARW: WMAPE=9.3%, RMSE=31.25 W/m².

5.7.1 Applicazione dei metodi di previsione della potenza

Di seguito, si riportano i risultati di previsione relativi alla coppia di stringhe denominate React1 per ciascuno dei metodi sviluppati. In primo luogo, è riportato un esempio di giornata soleggiata, il 03/03/2021, con una forma a campana ben riconoscibile

In Figura 27 è analizzata la previsione in potenza nel caso del Metodo 1. Si può notare come l'accuratezza della previsione di irradianza influenzi le performance della rete; in particolare, a destra è confrontata la potenza misurata generata dall'impianto fotovoltaico con la previsione a 24 ore ottenuta avendo come dati di irradianza in ingresso quelli di Figura 26 del modello WRF-ARW. A sinistra, invece, è mostrata una simulazione a posteriori volta a effettuare il confronto considerando nota l'irradianza della giornata in esame, cioè supponendo di avere a disposizione una previsione di irradianza con errore nullo rispetto alle reali osservazioni. Ovviamente, tale confronto può essere effettuato esclusivamente a posteriori, ossia una volta che si disponga delle reali misurazioni di irradianza. È evidente il netto miglioramento delle performance della rete nel caso di sinistra, con una diminuzione dell'errore percentuale di circa un terzo.




Figura 27. A sinistra, un confronto tra potenza misurata e prevista dalla rete neurale in caso di previsioni di irradianza esatte: WMAPE=4.6%, RMSE=144.11 W; a destra, un confronto tra potenza misurata e prevista dalla rete sulla base delle previsioni meteo del modello WRF-ARW: WMAPE=12.89%, RMSE=288.69 W.

In Figura 28, i risultati per la stessa giornata applicando il Metodo 2. Si può notare che l'errore è molto simile, sia nel caso di utilizzo delle previsioni WRF-ARW, a destra, sia nell'analisi a posteriori, a sinistra; ciò perché, in questo caso, l'errore nella previsione di irradianza rispetto al sensore posto in prossimità dell'impianto F50 è inferiore rispetto al caso precedente e ciò si riflette, inevitabilmente, anche sulla bontà della previsione di potenza.




Figura 28. A sinistra, un confronto tra potenza misurata e prevista dalla rete neurale in caso di previsioni di irradianza esatte: WMAPE=5.18%, RMSE=194.27 W; a destra, un confronto tra potenza misurata e prevista dalla rete sulla base delle previsioni meteo del modello WRF-ARW: WMAPE=6.46%, RMSE=200.31 W.

In Figura 29, infine, si riportano i risultati conseguiti con il Metodo 3. Si riscontra un sensibile miglioramento delle prestazioni della rete nel caso di previsioni di irradianza esatte; i risultati sono paragonabili con quanto ottenuto con il Metodo 1.

In definitiva, si può asserire che nel caso del React1, il Metodo 1 e 3 risultano egualmente validi, con errori molto simili. D'altronde ciò era prevedibile in quanto il Metodo 1 utilizza il piranometro posto sul React1 e, dunque, utilizza matrici di training con i valori esatti di irradianza rilevata sulla coppia di stringhe ed il Metodo 3 si basa su una strategia che dipende in larga misura dal punto di lavoro del React1; il metodo più

svantaggioso è, senza dubbio, il Metodo 2 che utilizza matrici di irradianza con valori dell'impianto F50: questo metodo potrebbe essere valido nei periodi dell'anno in cui non si verificano ombreggiamenti sistematici sui moduli dell'F40; in tal caso, la non rilevazione delle ombre fisse sui moduli dell'F40 da parte del piranometro dell'F50 sarebbe, infatti, irrilevante.




Figura 29. A sinistra, un confronto tra potenza misurata e prevista dalla rete neurale in caso di previsioni di irradianza esatte: WMAPE=4.59%, RMSE=169.21 W; a destra, un confronto tra potenza misurata e prevista dalla rete sulla base delle previsioni meteo del modello WRF-ARW: WMAPE=12.13%, RMSE=256.95 W.

Ci si concentra, ora, sul React2, la porzione di impianto interessata da ombre sistematiche a metà giornata e nel pomeriggio.

Con il Metodo 1, Figura 30, si ottengono risultati confrontabili con quelli del React 1. Ancora una volta, è mostrato il beneficio di poter disporre di una previsione esatta di irradianza; inoltre, si può notare che, soprattutto nel caso di destra, la rete non riesce a prevedere con esattezza il “buco” di potenza di metà giornata. Si ricordi che, infatti, le matrici di addestramento, in questo caso, non contengono i valori di irradianza del React2, ma quelli del React1; il fatto che la rete riesca comunque a prevedere una lieve depressione di potenza verso mezzogiorno è da imputare, ancora una volta, alle matrici di training: si ricordi, che in esse permane, comunque, il vettore delle potenze delle giornate passate il quale ha “memoria” degli avvallamenti nelle curve di potenza.




Figura 30. A sinistra, un confronto tra potenza misurata e prevista dalla rete neurale in caso di previsioni di irradianza esatte: WMAPE=4.89%, RMSE=126.62 W; a destra, un confronto tra potenza misurata e prevista dalla rete sulla base delle previsioni meteo del modello WRF-ARW: WMAPE=11.38%, RMSE=249.61 W.

In Figura 31 i risultati nel caso di applicazione del Metodo 2; i risultati non differiscono molto da quelli del Metodo 1: in entrambi i casi, infatti si utilizzano matrici con irradianze diverse da quelle effettive del React 2; ancora una volta, ottime previsioni di irradianza permetterebbero di abbassare l'errore – in questo caso di circa la metà.




Figura 31. A sinistra, un confronto tra potenza misurata e prevista dalla rete neurale in caso di previsioni di irradianza esatte: WMAPE=5.60%, RMSE=123.46 W; a destra, un confronto tra potenza misurata e prevista dalla rete sulla base delle previsioni meteo del modello WRF-ARW: WMAPE=9.72%, RMSE=284.56 W.

Figura 32 è un chiaro esempio di quanto la conoscenza dell'irradianza esatta su di un impianto in un arco di tempo definito insieme alla disponibilità di buone previsioni meteo possa portare a previsioni di potenza quasi perfette: come si evince dal grafico a sinistra la concomitanza di queste due condizioni porta l'errore intorno al 2%.




Figura 32. A sinistra, un confronto tra potenza misurata e prevista dalla rete neurale in caso di previsioni di irradianza esatte: WMAPE=2.4%, RMSE=63.99 W; a destra, un confronto tra potenza misurata e prevista dalla rete sulla base delle previsioni meteo del modello WRF-ARW: WMAPE=12.90%, RMSE=254.69 W.

In Figura 33, i risultati relativi al React 3. Nel grafico di destra si può notare che la previsione nel caso di dati meteo corretti è molto buona; il fatto che il React 3 abbia solamente un lieve ombreggiamento serale fa sì che l'imprecisione introdotta dal fatto che matrici di training non contengano i dati di irradianza relativi al React 3 non infici la bontà della previsione.




Figura 33. A sinistra, un confronto tra potenza misurata e prevista dalla rete neurale in caso di previsioni di irradianza esatte: WMAPE=3.02%, RMSE=79.62 W; a destra, un confronto tra potenza misurata e prevista dalla rete sulla base delle previsioni meteo del modello WRF-ARW: WMAPE=14.42%, RMSE=296.24 W.

Lo stesso dicasi per il Metodo 2:




Figura 34. A sinistra, un confronto tra potenza misurata e prevista dalla rete neurale in caso di previsioni di irradianza esatte: WMAPE=3.32%, RMSE=80.52 W; a destra, un confronto tra potenza misurata e prevista dalla rete sulla base delle previsioni meteo del modello WRF-ARW: WMAPE=3.83%, RMSE=74.36 W.

Per quanto riguarda il Metodo 3, si veda Figura 35. Fermo restando l'innegabile vantaggio derivante dal poter disporre di previsioni di potenza esatte – si noti il bassissimo errore del grafico di sinistra – il Metodo 3 apporta un significativo abbattimento dell'errore rispetto agli altri due Metodi: sempre riferendosi ai grafici

di sinistra si ha WMAPE = 3,02% per il Metodo 1, WMAPE = 3,32% per il Metodo 2 e WMAPE = 1,17% per il Metodo 3.




Figura 35. A sinistra, un confronto tra potenza misurata e prevista dalla rete neurale in caso di previsioni di irradianza esatte: WMAPE=1.17%, RMSE=29.11 W; a destra, un confronto tra potenza misurata e prevista dalla rete sulla base delle previsioni meteo del modello WRF-ARW: WMAPE=11.57%, RMSE=257.74 W.

Le considerazioni sopra esposte in merito ad una giornata di tipo soleggiato possono essere estese al caso che sarà presentato nel seguito di giornata variabile (11/03/2021).




Figura 36. A sinistra, un confronto tra potenza misurata e prevista dalla rete neurale in caso di previsioni di irradianza esatte: WMAPE=17.20%, RMSE=491.81 W; a destra, un confronto tra potenza misurata e prevista dalla rete sulla base delle previsioni meteo del modello WRF-ARW: WMAPE=63.30%, RMSE=1359.40 W.




Figura 37. A sinistra, un confronto tra potenza misurata e prevista dalla rete neurale in caso di previsioni di irradianza esatte: $WMAPE=30.87\%$, $RMSE=1024.60\,W$; a destra, un confronto tra potenza misurata e prevista dalla rete sulla base delle previsioni meteo del modello WRF-ARW: $WMAPE=82.7\%$, $RMSE=1973.5\,W$.




Figura 38. A sinistra, un confronto tra potenza misurata e prevista dalla rete neurale in caso di previsioni di irradianza esatte: $WMAPE=6.68\%$, $RMSE=198.45\,W$; a destra, un confronto tra potenza misurata e prevista dalla rete sulla base delle previsioni meteo del modello WRF-ARW: $WMAPE=15.11\%$, $RMSE=355.77\,W$.




Figura 39. A sinistra, un confronto tra potenza misurata e prevista dalla rete neurale in caso di previsioni di irradianza esatte: WMAPE=5.98%, RMSE=192.93 W; a destra, un confronto tra potenza misurata e prevista dalla rete sulla base delle previsioni meteo del modello WRF-ARW: WMAPE=24.20%, RMSE=645.29 W.




Figura 40. A sinistra, un confronto tra potenza misurata e prevista dalla rete neurale in caso di previsioni di irradianza esatte: WMAPE=36.44%, RMSE=967.68 W; a destra, un confronto tra potenza misurata e prevista dalla rete sulla base delle previsioni meteo del modello WRF-ARW: WMAPE=53.15%, RMSE=1722.50 W.




Figura 41. A sinistra, un confronto tra potenza misurata e prevista dalla rete neurale in caso di previsioni di irradianza esatte: WMAPE=4.00%, RMSE=89.64 W; a destra, un confronto tra potenza misurata e prevista dalla rete sulla base delle previsioni meteo del modello WRF-ARW: WMAPE=15.33%, RMSE=320.65 W.




Figura 42. A sinistra, un confronto tra potenza misurata e prevista dalla rete neurale in caso di previsioni di irradianza esatte: WMAPE=10.95%, RMSE=383.87 W; a destra, un confronto tra potenza misurata e prevista dalla rete sulla base delle previsioni meteo del modello WRF-ARW: WMAPE=22.20%, RMSE=568.15 W.




Figura 43. A sinistra, un confronto tra potenza misurata e prevista dalla rete neurale in caso di previsioni di irradianza esatte: WMAPE=74.17%, RMSE=1823.40 W; a destra, un confronto tra potenza misurata e prevista dalla rete sulla base delle previsioni meteo del modello WRF-ARW: WMAPE=160.00%, RMSE=7099.00 W.




Figura 44. A sinistra, un confronto tra potenza misurata e prevista dalla rete neurale in caso di previsioni di irradianza esatte: WMAPE=1.91%, RMSE=45.35 W; a destra, un confronto tra potenza misurata e prevista dalla rete sulla base delle previsioni meteo del modello WRF-ARW: WMAPE=14.55%, RMSE=322.73 W.

Tabella 8a. Errore percentuale WMAPE (%) ottenuto nelle previsioni a 24 h con i tre metodi – 03/03/2021

	Metodo 1	Metodo 1	Metodo 2	Metodo 2	Metodo 3	Metodo 3
	GHI misurata	WRF-ARW	GHI misurata	WRF-ARW	G_i calcolata	WRF-ARW
React 1	4,60	12,89	5,18	6,46	4,59	12,13
React 2	4,89	11,38	5,60	9,72	2,40	12,90
React 3	3,02	14,42	3,32	3,83	1,17	11,57

Tabella 8b. Errore percentuale medio WMAPE (%) ottenuto nelle previsioni a 24 h con i tre metodi – 11/03/2021

	Metodo 1	Metodo 1	Metodo 2	Metodo 2	Metodo 3	Metodo 3
	GHI misurata	WRF-ARW	GHI misurata	WRF-ARW	G_i calcolata	WRF-ARW
React 1	17,20	63,30	30,87	82,70	6,68	15,11

	Metodo 1	Metodo 1	Metodo 2	Metodo 2	Metodo 3	Metodo 3
React 2	5,98	24,20	36,44	53,15	4,00	15,33
React 3	10,95	22,20	74,17	160,00	1,91	14,55

Tabella 9a. Errore quadratico medio RMSE (W) ottenuto nelle previsioni a 24 h con i tre metodi – 03/03/2021

	Metodo 1	Metodo 1	Metodo 2	Metodo 2	Metodo 3	Metodo 3
	GHI misurata	WRF-ARW	GHI misurata	WRF-ARW	G_t calcolata	WRF-ARW
React 1	144,11	288,69	194,27	200,31	169,21	256,95
React 2	126,62	249,61	123,46	284,56	63,99	254,69
React 3	79,62	269,24	80,52	74,36	29,11	257,74

Tabella 9b. Errore quadratico medio RMSE (W) ottenuto nelle previsioni a 24 h con i tre metodi – 11/03/2021

	Metodo 1	Metodo 1	Metodo 2	Metodo 2	Metodo 3	Metodo 3
	GHI misurata	WRF-ARW	GHI misurata	WRF-ARW	G_t calcolata	WRF-ARW
React 1	491,81	1359,40	1024,60	1973,50	198,45	355,77
React 2	192,93	645,29	967,68	1722,50	89,64	320,65
React 3	383,87	568,15	1832,40	7099,00	45,35	322,73

Osservando i risultati riepilogati nelle Tabelle 8 e 9, si può concludere che:

- il Metodo 1 può essere applicato con successo solo per il React1 oppure nei periodi dell'anno in cui non si hanno ombre sistematiche sull'impianto fotovoltaico;
- il Metodo 2, in cui si utilizza un piranometro non soggetto ad ombreggiamenti, è invece efficace, similmente al Metodo 1, in assenza di ombre sistematiche su tutto l'impianto;
- il Metodo 3 è senza dubbio il più indicato per ottenere previsioni di potenza accurate; ciò è particolarmente vero per giornate parzialmente nuvolose poiché la forma-chiusa dell'irradianza consente di tener conto delle fluttuazioni della grandezza durante le 24 ore.

In ultimo, si riportano nelle Tabelle 10 ed 11, gli errori relativi anche alla somma dei risultati ottenuti sui 3 React. È evidente che la somma dei tre profili apporti un sensibile miglioramento delle prestazioni, imputabile ad una compensazione degli errori dei singoli React che fa sì che l'errore complessivo vada a diminuire.

Tabella 10a. Errori percentuali WMAPE (%) ottenuti nelle previsioni a 24 h della produzione dell'intero impianto FV (18,2 kW) con i tre metodi– 03/03/2021

	Metodo 1	Metodo 1	Metodo 2	Metodo 2	Metodo 3	Metodo 3
	GHI misurata	WRF-ARW	GHI misurata	WRF-ARW	G_t calcolata	WRF-ARW
R1+R2+R3	3,32	12,92	3,61	4,40	2,20	11,88

Tabella 10b. Errori percentuali WMAPE (%) ottenuti nelle previsioni a 24 h della produzione dell'intero impianto FV (18,2 kW) con i tre metodi – 11/03/2021

	Metodo 1	Metodo 1	Metodo 2	Metodo 2	Metodo 3	Metodo 3
	GHI misurata	WRF-ARW	GHI misurata	WRF-ARW	G_t calcolata	WRF-ARW
R1+R2+R3	8,86	24,61	45,5	91,49	2,6	13,93

Tabella 11a. Errori quadratici medi RMSE (W) ottenuti nelle previsioni a 24 h della produzione dell'intero impianto FV (18,2 kW) con i tre metodi– 03/03/2021

	Metodo 1	Metodo 1	Metodo 2	Metodo 2	Metodo 3	Metodo 3
	GHI misurata	WRF-ARW	GHI misurata	WRF-ARW	G_t calcolata	WRF-ARW
R1+R2+R3	257,18	774,78	239,98	336,39	191,68	718,00

Tabella 11b. Errori quadratici medi RMSE (W) ottenuti nelle previsioni a 24 h della produzione dell'intero impianto FV (18,2 kW) con i tre metodi – 11/03/2021

	Metodo 1	Metodo 1	Metodo 2	Metodo 2	Metodo 3	Metodo 3
	GHI misurata	WRF-ARW	GHI misurata	WRF-ARW	G_t calcolata	WRF-ARW
R1+R2+R3	687,32	1622,80	3382,62	8532,70	187,28	962,05

6 Rete neurale per la previsione del carico elettrico

La rete neurale implementata in questo capitolo ha come obiettivo la previsione a 24 ore delle curve di carico elettrico dell'edificio F40. Il consumo elettrico dell'edificio F40 può essere analizzato tenendo conto dei diversi carichi; questi sono illustrati in riferimento al piano cui appartengono ed al loro tipo.

6.1 Caratteristiche dei carichi

L'F40 è un edificio adibito ad uso ufficio e comprende anche dei laboratori. In particolare, il piano terra è quello meno frequentato e, dunque, avrà minori consumi elettrici mentre il primo ed il secondo sono i piani più attivi. Le misure relative ai carichi elettrici sono acquisite per mezzo di sensori installati in vari punti dell'edificio e registrate nel medesimo file giornaliero nel quale troviamo i dati utilizzati per la previsione di potenza fotovoltaica; quindi, anche questi campioni sono acquisiti a passo di 15 secondi.

Alcuni dei carichi in esame sono di tipo monofase, altri trifase, in particolare si hanno:

- Carichi monofase: potenza di cabina (linea 1), pompa di calore (linea 2) e luci di cabina (linea 3)
- Carichi trifase (relativi ai piani primo e secondo): luci di emergenza, fan-coil, forza motrice e luci degli uffici.

Così come nella previsione di potenza fotovoltaica, le previsioni dei carichi verranno fatte a livello di singolo React, avremo quindi 3 previsioni sulle linee L1, L2 e L3. Per completezza verrà fatta anche la previsione del carico complessivo di linea L123 ottenuto sommando le previsioni sulle singole linee. Nella figura seguente è mostrato lo schema a blocchi dell'impianto dell'F40 in cui sono evidenziati il generatore fotovoltaico, il sistema di storage, i carichi di edificio e la rete:




Figura 45. Sinottico Dimostratore F40.

Nella preparazione dei dati per l'addestramento si è deciso di sommare i consumi elettrici su ogni linea; i carichi trifase saranno, quindi, suddivisi sulle tre fasi e non considerati distintamente.




Figura 46. Profilo di carico settimanale sulla linea L1.




Figura 47. Profilo di carico settimanale sulla linea L2.




Figura 18. Profilo di carico settimanale sulla linea L3.

È importante evidenziare che, tra i carichi considerati, alcuni mostrano una dipendenza dalle presenze delle persone altri, al contrario, possono considerarsi a valor medio costante nel corso della settimana. Alle figure che seguono, da Figura 49 a 63, sono associate delle tabelle esplicative che riassumono le caratteristiche di ciascuno dei carichi mostrati: alcuni di essi sono fortemente dipendenti dalle presenze, mentre altri no, alcuni variano molto nel tempo, altri meno ed infine, per alcuni carichi sono stati considerati, nelle matrici di training e nelle previsioni, i valori medi anziché le curve vere e proprie; ciò è stato fatto per quei carichi il cui valor medio rientra entro poche centinaia di Watt. Nelle tabelle a seguire la “x” indica che per quel determinato carico non è stato considerato il valor medio bensì la curva vera e propria:




Figura 49. Profilo di carico settimanale della potenza di cabina: presenta bassa variabilità e dipendenza dalle presenze ed ha valore medio di 82.4 W.




Figura 50. Profilo settimanale della potenza delle luci normali su linea L1: presenta variabilità media ed elevata dipendenza dalle presenze.




Figura 51. Profilo settimanale della potenza dei FanCoil su linea L1: presenta bassa variabilità e dipendenza dalle presenze ed ha un valore medio trascurabile.




Figura 52. Profilo settimanale della potenza della forza motrice su linea L1: presenta alte variabilità e dipendenza dalle presenze.




Figura 53. Profilo settimanale della potenza delle luci d'emergenza: presenta una media variabilità ed una bassa dipendenza dalle presenze; ha valore medio di 265 W.




Figura 54. Profilo settimanale della potenza delle luci su linea L2: presenta una media variabilità ed un'elevata dipendenza dalle presenze.




Figura 55. Profilo settimanale della potenza dei FanCoil su linea L2.




Figura 56. Profilo settimanale della potenza della forza motrice su linea L2: presenta elevate variabilità e dipendenza dalle presenze.




Figura 57. Profilo settimanale della potenza della pompa di calore: presenta un'elevata variabilità ed una bassa dipendenza dalle presenze.




Figura 58. Profilo settimanale della potenza delle luci d'emergenza su linea L2: presenta una media variabilità ed una bassa dipendenza dalle presenze; ha valore medio di 302.3 W.




Figura 59. Profilo settimanale della potenza delle luci della cabina: presenta basse variabilità e dipendenza dalle presenze; ha valore medio trascurabile.




Figura 60. Profilo settimanale della potenza delle luci su linea L3: presenta elevate variabilità e dipendenza dalle presenze.




Figura 61. Profilo settimanale della potenza dei FanCoil su linea L3: presenta basse variabilità e dipendenza dalle presenze; ha valore medio trascurabile.




Figura 62. Profilo settimanale della potenza della forza motrice su linea L3: presenta un'elevata variabilità ed una media dipendenza dalle presenze.




Figura 63. Profilo settimanale della potenza delle luci d'emergenza su linea L3: presenta basse variabilità e dipendenza dalle presenze; ha valore medio di 312.35 W.




Figura 64. Energia giornaliera su ogni carico della linea L1 calcolata da lunedì a domenica.




Figura 65. Energia giornaliera su ogni carico della linea L2 calcolata da lunedì a domenica.




Figura 66. Energia giornaliera su ogni carico della linea L3 calcolata da lunedì a domenica.

Gli istogrammi nelle Figure da 64 a 66 riportano l'energia complessiva giornaliera per i diversi carichi nel corso di una settimana; si può notare la differenza nei consumi energetici nei giorni feriali e festivi: infatti, i consumi maggiori sono determinati dalla forza motrice e dalle luci degli uffici. Questa differenza dipende dall'assenza di attività umana durante la chiusura del centro; perciò si è scelto di implementare un modello neurale valido solo nei giorni feriali, caratterizzati da una grande variabilità dei carichi elettrici. I consumi dei giorni festivi sono determinati in gran parte da carichi con bassa variabilità e ciò ha suggerito di assegnare ai carichi festivi un valore costante pari alla media del valore di fondo della serata precedente; in questo modo è, inoltre, possibile eliminare errori che potrebbero sorgere andando ad includere giornate con bassa variabilità nel training set.

6.2 Metodologia

Per la previsione dei profili di carico elettrico dell'edificio F40, si è optato per l'utilizzo di reti neurali di tipo dinamico.

Le reti neurali dinamiche sono caratterizzate dalla presenza di feedback o ritardi, con la conseguenza che gli output correnti non dipendono solo dagli input, ma anche dagli output e dagli stati precedenti della rete; tali reti, a differenza di quelle statiche, sono caratterizzate da diversi gradi di memoria, cosa che le rende adatte all'utilizzo per fini previsivi, potendo essere addestrate a riconoscere andamenti tempo varianti. Un'importante distinzione nella classe delle reti neurali dinamiche è quella tra reti *feed-forward* e *ricorrenti*. Nel primo caso, la memoria della rete si limita ai ritardi degli input ed in questo caso si può asserire che la rete disponga di una memoria limitata ad un certo numero di dati; nel secondo caso, la memoria è determinata da ulteriori connessioni (feedback) che si vanno ad aggiungere alla struttura della rete: ciò fa sì che la memoria sia pressoché illimitata. In particolare, sono presenti nella struttura della rete uno o più rami di retroazione.

Si è scelto di utilizzare una rete appartenente al primo gruppo; in particolare, si è utilizzata la più semplice rete a ritardo fissato: la FTDNN (Focused Time Delay Neural Network) che consiste in una classica FF cui è aggiunta una linea di ritardo fissato in ingresso, TDL (Tapped Delay Line). La rete mantiene in memoria le informazioni passate sotto forma di linee di ritardo fissate. Le reti dinamiche di tipo focalizzato appartengono ad una classe di reti in cui la caratteristica dinamica è presente solamente nello strato di input di una rete FF statica.




Figura 67. Architettura di una rete neurale di tipo FTD.

In Figura 67, l'FTDNN di base che è costituita da due componenti: una struttura di memoria ed un associatore non lineare. La struttura della memoria è una linea di ritardo temporale che contiene i più recenti ingressi, p , generati dall'elemento di ritardo rappresentato dall'operatore d , mentre l'associatore è la classica rete FF. La struttura della memoria conserva le informazioni rilevanti del passato e l'associatore utilizza la memoria per prevedere le uscite future. Una caratteristica particolare dell'FTDNN è che la struttura della memoria è focalizzata sullo strato di input, diversamente dalla convenzionale rete neurale TDNN (Time Delay Neural Network). Uno dei principali vantaggi dell'FTDNN è che è meno complessa della classica TDNN, ma mostra capacità di elaborazione dei modelli temporali comparabili.

Successivamente, si è pensato di confrontare i risultati con quelli di un'ulteriore rete; si è scelta una rete Autoregressiva Non-Lineare (NAR: NonLinear Autoregressive) che mostra buoni risultati nella previsione di serie non lineari.

6.3 Sviluppo del modello neurale

Le tipologie di rete utilizzate riescono a prevedere serie temporali sulla base di un ritardo fissato; nel nostro caso questo parametro è stato fissato a 24 ore. Per quanto riguarda l'addestramento della rete, la dimensione del training set è stata variata contestualmente al numero di neuroni: le matrici di training variano da un minimo di 7 giorni ad un massimo di 28 mentre il range di variazione dei neuroni è da 8 a 30. È importante sottolineare che la costruzione delle matrici di training è più semplice riguardo a quelle utilizzate per il training della rete FF per la potenza prodotta da fotovoltaico. Infatti, le reti per la previsione di serie temporali hanno bisogno unicamente dei valori precedenti della grandezza da predire. Perciò, in questo caso, ciò che è importante è la disponibilità di un vettore degli output passati sufficientemente affidabile.

A causa della situazione contingente relativa alla pandemia mondiale, è stato difficile reperire sufficienti dati riguardanti il carico elettrico. Per alcuni mesi gli uffici sono stati carenti di presenze e per questo non è stato possibile disporre di dati rappresentativi sui consumi elettrici a causa dello scarso utilizzo del Centro Ricerche. Inoltre, spesso è stato difficile individuare una ripetibilità nei dati a causa di giornate di chiusure forzate infrasettimanali: questa discontinuità nei dati di input ha reso complessa la fase di processamento delle matrici di training. Tuttavia, grazie alle parziali riaperture negli ultimi mesi è stato possibile identificare blocchi di 30 giorni continuativi di dati validi.

Per entrambi i tipi di rete, a partire dall'architettura scelta, si è scelto di implementare un ramo di retroazione nella fase di previsione; questa modifica permette di creare un loop che, ad ogni iterazione, riporta in ingresso alla rete l'uscita calcolata dalla stessa al passo precedente: in questo modo si dotano le reti di un comportamento ricorrente che garantisce migliori capacità nella previsione di serie temporali.

6.4 Risultati

In questo paragrafo si analizzano i risultati ottenuti con le due diverse tipologie di rete neurale applicati a due giornate diverse e per ciascuna delle tre linee dell'impianto elettrico.

Le due giornate di test sono state scelte sulla base della disponibilità di dati contigui nelle matrici di training: è stato necessario individuare periodi di almeno 30 giorni di servizio continuo dei server dell'impianto per assicurare la presenza di 28 giorni di training consecutivi senza interruzioni o giornate mancanti, in modo da poter disporre di una serie temporale significativa.

Si riportano nel seguito i risultati ottenuti.

Come si nota nelle figure seguenti, i risultati sono molto buoni e le due tipologie di reti risultano entrambe molto valide nell'applicazione in esame. Le strategie sono state testate su due giornate con curva di carico leggermente differente. Si è costruito un training set costituito da massimo 4 settimane: in questo modo la rete ha avuto modo di apprendere gli andamenti da più "esempi". Estendere ulteriormente le matrici di training sarebbe controproducente in quanto l'inclusione di dati troppo remoti farebbe venire meno la correlazione con i dati attuali.




Figura 68. A sinistra la previsione della potenza della linea L a 24h ottenuta con la FTDNN (MAPE=7,15%), a destra la previsione ottenuta con la Narnet (MAPE=8,59%).




Figura 69. A sinistra la previsione della potenza della linea L2 a 24h ottenuta con la FTDNN (MAPE=4,77%), a destra la previsione ottenuta con la Narnet (MAPE=6,62%).




Figura 70. A sinistra la previsione della potenza della linea L3 a 24h ottenuta con la FTDNN (MAPE=7,28%), a destra la previsione ottenuta con la Narnet (MAPE=7,03%).




Figura 71. A sinistra la previsione della potenza della linea 1 a 24h ottenuta con la FTDNN (MAPE=9,74%), a destra la previsione ottenuta con la Narnet (MAPE=8,23%).




Figura 72. A sinistra la previsione della potenza della linea 2 a 24h ottenuta con la FTDNN (MAPE=6,44%), a destra la previsione ottenuta con la Narnet (MAPE=5,98%).




Figura 73. A sinistra la previsione della potenza della linea 2 a 24h ottenuta con la FTDNN (MAPE=6,40%), a destra la previsione ottenuta con la Narnet (MAPE=7,59%).

Tabelle 12 e 13 riassumono i risultati ottenuti per quattro giornate 25 e 26/02/2021 e 04 e 12/03/2021; in generale, si può notare che l'errore percentuale è quasi sempre inferiore al 10% e che per *Day1* e *Day 4* è necessario un numero superiore di neuroni per il raggiungimento di buone performance delle reti. In definitiva, entrambe le metodologie risultano efficienti per la previsione del fabbisogno giornaliero dei carichi di edificio.

Tabella 12a. Errore percentuale MAPE (%) ottenuto nelle previsioni a 24 h per le tre linee – 25/02/2021 (Day1)

	FTDNN - MAPE (%)	# neuroni	NARNET – MAPE (%)	# neuroni
Linea L1	7,15	20	8,59	28
Linea L2	4,77	22	6,62	22
Linea L3	7,28	26	7,03	28

Tabella 12b. Errore percentuale MAPE (%) ottenuto nelle previsioni a 24 h per le tre linee – 26/02/2021 (Day2)

	FTDNN - MAPE (%)	# neuroni	NARNET – MAPE (%)	# neuroni
Linea L1	9,74	12	8,23	12
Linea L2	6,44	14	5,98	14
Linea L3	6,40	10	7,59	8

Tabella 12c. Errore percentuale MAPE (%) ottenuto nelle previsioni a 24 h per le tre linee – 04/03/2021 (Day3)

	FTDNN - MAPE (%)	# neuroni	NARNET – MAPE (%)	# neuroni
Linea L1	7,7	10	10,09	10
Linea L2	4,3	14	4,5	22
Linea L3	6,34	28	6,91	24

Tabella 12d. Errore percentuale MAPE (%) ottenuto nelle previsioni a 24 h per le tre linee – 12/03/2021 (Day4)

	FTDNN - MAPE (%)	# neuroni	NARNET – MAPE (%)	# neuroni
Linea L1	9,89	22	10,62	16
Linea L2	5,89	28	5,69	28

	FTDNN - MAPE (%)	# neuroni	NARNET – MAPE (%)	# neuroni
Linea L3	18,39	24	19,36	28

Tabella 13a. Errore quadratico medio RMSE (W) ottenuto nelle previsioni a 24 h per le tre linee – 25/02/2021 (Day1)

	FTDNN - RMSE (W)	# neuroni	NARNET – MAPE (%)	# neuroni
Linea L1	165,28	20	190,96	28
Linea L2	111,32	22	143,29	22
Linea L3	126,09	26	134,28	28

Tabella 13b. Errore quadratico medio RMSE (W) ottenuto nelle previsioni a 24 h per le tre linee – 26/02/2021 (Day2)

	FTDNN - RMSE (W)	# neuroni	NARNET – MAPE (%)	# neuroni
Linea L1	202,49	12	192,58	12
Linea L2	151,98	14	149,38	14
Linea L3	118,35	10	137,98	8

Tabella 13c. Errore quadratico medio RMSE (W) ottenuto nelle previsioni a 24 h per le tre linee – 04/03/2021 (Day3)

	FTDNN - RMSE (W)	# neuroni	NARNET – RMSE (W)	# neuroni
Linea L1	292,88	10	310,93	10
Linea L2	123,72	14	121,61	22
Linea L3	139,55	28	152,73	24

Tabella 13d. Errore quadratico medio RMSE (W) ottenuto nelle previsioni a 24 h per le tre linee – 12/03/2021 (Day4)

	FTDNN - RMSE (W)	# neuroni	NARNET – RMSE (W)	# neuroni
Linea L1	236,18	22	237,08	16
Linea L2	167,38	28	154,67	28
Linea L3	706,42	24	718,87	28

In ultimo, si riportano nelle Tabelle 14 e 15, gli errori relativi anche alla somma dei risultati ottenuti sulle 3 linee. È evidente che la somma dei tre profili apporti un sensibile miglioramento delle prestazioni, imputabile ad una compensazione degli errori delle singole linee che fa sì che l'errore complessivo vada a diminuire.

Tabella 14. Errori percentuali MAPE (%) ottenuti nelle previsioni a 24 h del carico di edificio complessivo (L123).

	FTDNN - MAPE (%)	NARNET – MAPE (%)
Linea L1+L2+L3 – Day1	3,84	5,03
Linea L1+L2+L3 – Day2	3,63	4,00
Linea L1+L2+L3 – Day3	4,69	4,92
Linea L1+L2+L3 – Day4	9,32	10,24

Tabella 15. Errori quadratici medi RMSE (W) ottenuti nelle previsioni a 24 h del carico di edificio complessivo (L123).

	FTDNN - RMSE (W)	NARNET - RMSE (W)
Linea L1+L2+L3 – Day1	252,85	301,83
Linea L1+L2+L3 – Day2	229,33	305,39
Linea L1+L2+L3 – Day3	500,74	482,30
Linea L1+L2+L3 – Day4	745,79	819,18

7 Conclusioni

Le attività svolte hanno riguardato lo sviluppo di metodi basati su Reti Neurali Artificiali per la previsione della potenza prodotta dall'impianto fotovoltaico installato sulla copertura dell'edificio F40 e per la stima del fabbisogno energetico del carico relativo al medesimo edificio.

Per quanto riguarda la stima della potenza prodotta, dopo un'accurata analisi dei dati disponibili sono state create le matrici di addestramento costituite dalle grandezze tempo, irradianza solare, temperatura ambiente e potenza al quarto d'ora precedente. Si è optato per un'architettura semplice ma, che al tempo stesso garantisse accuratezza e rapidità di calcolo. La classica rete Feed-Forward è stata adattata al caso in esame implementando un loop ricorsivo per tener conto, ad ogni passo di calcolo, dell'ultimo valore di potenza stimato. Inoltre, è stata utilizzata una procedura analitica per il calcolo istantaneo della potenza sul piano dei moduli che ha permesso di rilevare qualsiasi tipo di ombreggiamento sugli stessi. Ciò ha permesso di ottenere ottimi risultati di previsione con errori, nella maggioranza dei casi, inferiori al 5 % anche nel caso di giornate particolarmente nuvolose.

In relazione alla previsione dei carichi elettrici, sono state implementate due differenti reti neurali di tipo dinamico, una rete Time-Delay ed una NAR. In entrambi i casi sono stati ottenuti risultati molto buoni con errori inferiori al 10%.

In particolare, dalla stima dello scarto di energia tra previsione e reale trend giornaliero, è evidente che l'accuratezza delle reti legittima il loro utilizzo nelle future attività in programma riguardanti lo sviluppo di strategie per lo scambio di energia con la rete elettrica in base al surplus/deficit tra produzione e consumo. Ciò permetterà una gestione flessibile della domanda e dell'offerta di energia e, quindi, l'inserimento nelle dinamiche del mercato elettrico.

8 Riferimenti bibliografici

1. De Lia, F., Schioppo, R., Lo Presti, R., Pizzuti, S., Romanello, F., Romano, S., & Zinzi, M. Tecnologie per gli Smart Buildings di seconda generazione. Report RdS/PTR2019/004.
2. Radicioni, M., Lucaferri, V., De Lia, F., Laudani, A., Lo Presti, R., Lozito, G. M., Riganti Fulginei, F., Schioppo, R., & Tucci, M. (2021). Power Forecasting of a Photovoltaic Plant Located in ENEA Casaccia Research Center. *Energies*, 14(3), 707.
3. Carrasco, M., Laudani, A., Lozito, G. M., Mancilla-David, F., Riganti Fulginei, F., & Salvini, A. (2017). Low-cost solar irradiance sensing for pv systems. *Energies*, 10(7), 998.

9 Abbreviazioni ed acronimi

AI: Artificial Intelligence

ANN: Artificial Neural Network

BEMS: Building Energy Management System

GHI: Global Horizontal Irradiance

RH: Relative Humidity

FF: Feed-Forward

MSE: Mean Square Error

RMSE: Root Mean Square Error

MAPE: Mean Absolute Percentage Error

WMAPE: Weighted Mean Absolute Percentage Error

D-FFNN: Dynamic Feed-Forward Neural Network

WMO: World Meteorological Organization

WRF: Weather Research and Forecasting Model

ARW: Advanced Research WRF

GFS: Global Forecast System

FTDNN: Focused Time Delay Neural Network

TDL: Tapped Delay Network

NAR: Non-Linear Autoregressive

Antonino Laudani nasce a Catania il 18 Luglio 1973. Nel gennaio 1999 consegue la Laurea in Ingegneria Elettronica presso l'Università di Catania, con votazione 110 su 110 e lode, e nel febbraio 2003 consegue il titolo di Dottore di Ricerca in Ingegneria Elettronica, presso l'Università di Reggio Calabria. Dal 2003 al 2011 ha svolto attività di ricerca presso il Dipartimento di ingegneria Elettrica Elettronica e dei Sistemi, prima come titolare di una borsa post-dottorato in Ingegneria Elettrica e poi come assegnista per il settore scientifico disciplinare ING-IND/31 Elettrotecnica. Dal 1° settembre 2011 presta servizio come ricercatore (e dal 1° marzo 2018 come professore associato) presso il Dipartimento di Ingegneria dell'Università degli Studi Roma Tre nel S.S.D ING-IND/31 Elettrotecnica. L'attività scientifica di Antonino Laudani si è svolta essenzialmente su tematiche tipiche dell'Elettrotecnica ed ha riguardato soprattutto aspetti relativi allo studio di metodologie di calcolo di campi elettromagnetici e loro applicazione nell'ambito dell'analisi e della simulazione di dispositivi elettromagnetici, nonché lo sviluppo di circuiti ed algoritmi, anche basati su tecniche di intelligenza artificiale, per la predizione e l'elaborazione di segnali mono e multidimensionali e per la soluzione di problemi inversi o di ottimizzazione, per il modellamento efficiente di sistemi fotovoltaici e per il monitoraggio ambientale. La maggior parte delle tematiche di ricerca sono state condotte nell'ambito di collaborazioni internazionali (Università di Denver Colorado, ESA-Agenzia Spaziale Europea, National Physics Laboratory, ecc.) o di progetti di ricerca di rilevante interesse nazionale, o in collaborazione con i ricercatori di Università ed Enti di ricerca italiani (INGV, CNR, ENEA), o nell'ambito di convenzioni con i gruppi di ricerca di diverse aziende (STMicroelectronics, Galileo Avionica, Selex Communications, Innosystec, ecc.) per la soluzione di problematiche di interesse strategico per l'industria. I risultati più significativi di questa attività sono stati presentati nel corso delle maggiori conferenze internazionali del settore quali CEFC, COMPUMAG, ELECTROSOFT, IVEC, SCEE, CEM, OIPE, ISEF, INTERMAG ecc., patrocinate dall'IEEE, e sono apparsi su qualificate riviste internazionali, ricevendo apprezzamento e riconoscimento anche con premi internazionali. Antonino Laudani dal 2001 è membro dell'International Compumag Society, dal 2009 è membro dell'IEEE society e dal 2013 è membro dell'American Association for the Advancement of Science (AAAS) e dal 2017 è membro dell'International Solar Energy Society (ISES) e della Società Italiana Caos e Complessità (SICC). La produzione scientifica di Antonino Laudani comprende oggi oltre 130 pubblicazioni scientifiche a diffusione internazionale.

Valentina Lucaferri nasce a Bracciano (RM) il 20 Dicembre 1991. A Marzo 2014 consegue la Laurea di primo livello in Ingegneria Elettronica presso l'Università degli Studi di Roma Tre, con votazione 103/110, con tesi sperimentale dal titolo "Utilizzazione di reti neurali artificiali nell'ambito della compensazione armonica nei sistemi elettrici di potenza". Il progetto di tesi ha riguardato l'implementazione di reti neurali artificiali per la previsione del contenuto armonico generato da un insieme di carichi non-lineari. A Marzo 2016 consegue la Laurea Magistrale in Ingegneria Elettronica per l'industria e l'innovazione con votazione 110 e Lode/110 presso l'Università degli Studi di Roma Tre con tesi dal titolo "Ottimizzazione di dispositivi piezoelettrici per il recupero energetico". Il lavoro di tesi è stato incentrato sulla caratterizzazione di dispositivi piezoelettrici,

in grado di generare energia elettrica sfruttando l'energia derivante dalle vibrazioni meccaniche. I modelli realizzati sono stati implementati per simulare il comportamento del dispositivo piezoelettrico inserito all'interno del manto stradale. A Maggio 2020 consegue il titolo di Dottore di Ricerca in Elettronica Applicata, presso l'Università degli Studi di Roma Tre con la tesi dal titolo "Numerical Simulation and Analysis of Non-Linear Dynamic Systems for Electrical Applications". Corso di Dottorato in Elettronica Applicata sul tema "Identificazione di modelli e tecniche di ottimizzazione di dispositivi non lineari per applicazioni di ingegneria elettrica ed elettronica" presso l'Università degli Studi di Roma Tre. Durante il triennio, è stato svolto un periodo (Maggio 2019 – Novembre 2019) presso il Centro Ricerche ENEA di Casaccia; tutor: Ing. Francesco De Lia. Le attività svolte hanno riguardato l'implementazione di algoritmi basati sull'intelligenza artificiale per la previsione dell'energia prodotta da un impianto fotovoltaico con accumulo.

Il lavoro di tesi ha riguardato l'analisi e la simulazione di sistemi non-lineari mediante algoritmi di ottimizzazione basati sull'intelligenza artificiale. Le soluzioni proposte sono state implementate per modellare i comportamenti non-lineari alla base di alcune applicazioni elettriche: sistemi di accumulo e pannelli fotovoltaici. Assegno di ricerca (Settembre 2020 - ad oggi) presso l'Università degli Studi di Roma Tre. Le attività di ricerca in corso fanno parte del programma dal titolo "Sviluppo di strategie basate su tecniche di intelligenza artificiale per la gestione dei flussi di potenza in Smart Building". (responsabile Prof. Francesco Riganti Fulginei). Le strategie sono sviluppate e testate in collaborazione con il Centro Ricerche ENEA di Casaccia, che ha messo a disposizione impianti fotovoltaici connessi a sistemi di accumulo e smart building per validare le soluzioni proposte basate su tecniche di machine learning. Tutor: Ing. Francesco De Lia.

Martina Radicioni nasce a Roma il 04 Settembre 1991. A Marzo 2014 consegue la Laurea di primo livello in Ingegneria Elettronica presso l'Università degli Studi di Roma Tre con votazione 107/110, con tesi sperimentale dal titolo "Utilizzazione di reti neurali artificiali nell'ambito della modellazione di moduli fotovoltaici". Utilizzazione di reti neurali artificiali nell'ambito della modellazione di moduli fotovoltaici. A Marzo 2016 consegue la Laurea Magistrale in Ingegneria Elettronica per l'industria e l'innovazione con votazione 110 e Lode/110 presso l'Università degli Studi di Roma Tre con tesi dal titolo "Configurazioni ottime di interconnessione di dispositivi piezoelettrici per l'energy harvesting". Il lavoro di tesi è stato incentrato sullo sviluppo di modelli per l'ottimizzazione delle interconnessioni tra dispositivi piezoelettrici per la massimizzazione dell'energia prodotta dalle vibrazioni del manto stradale. A Maggio 2020 consegue il titolo di Dottore di Ricerca in Elettronica Applicata, presso l'Università degli Studi di Roma Tre con la tesi dal titolo "Advanced Circuit Modelling and Embedded Applications for Photovoltaic Energy Generation". Corso di Dottorato in Elettronica Applicata sul tema "Modelli circuitali avanzati per celle, moduli e sistemi fotovoltaici" presso l'Università degli Studi di Roma Tre (Novembre 2016 – Ottobre 2019). Durante il triennio, è stato svolto un periodo (Maggio 2019 – Novembre 2019) presso il Centro Ricerche ENEA di Casaccia; tutor: Ing. Francesco De Lia. Le attività svolte hanno riguardato l'implementazione di algoritmi basati sull'intelligenza artificiale per la previsione dell'energia prodotta da un impianto fotovoltaico con accumulo.

Il lavoro di tesi ha riguardato lo studio delle principali questioni correlate all'ottimizzazione dell'energia elettrica prodotta da sistemi fotovoltaici e lo sviluppo di soluzioni atte alla massimizzazione dell'efficienza degli stessi. Sono state implementate strategie per la previsione dell'irradianza solare su impianti fotovoltaici e metodi per il recupero della potenza elettrica in condizioni di ombreggiamento, così come sistemi di monitoraggio delle performance di dispositivi fotovoltaici. Assegno di ricerca (Settembre 2020 - ad oggi) presso l'Università degli Studi di Roma Tre. Le attività di ricerca in corso fanno parte del programma dal titolo "Sviluppo di strategie basate su tecniche di intelligenza artificiale per la gestione dei flussi di potenza in Smart Building". (responsabile Prof. Francesco Riganti Fulginei). Le attività sono svolte in collaborazione con il Centro Ricerche ENEA di Casaccia (sotto la guida dell'Ing. Francesco De Lia) che ha messo a disposizione i propri impianti fotovoltaici e sistemi di accumulo per la validazione delle tecniche di intelligenza artificiale sviluppate.

Francesco Riganti Fulginei è nato a Gualdo Tadino (PG) il 18/09/1972. Ha conseguito la Laurea in Ingegneria Elettronica (vecchio ordinamento) nel dicembre 2000, discutendo la tesi dal titolo: "Algoritmi genetici applicati alla modellazione statica e dinamica di dispositivi a nucleo ferromagnetico", presso l'Università degli Studi Roma Tre. Ha conseguito il titolo di Dottore di Ricerca in Ingegneria dell'Elettronica Biomedica, dell'Elettromagnetismo e delle Telecomunicazioni presso l'Università degli Studi Roma Tre in data 27/4/2007. Ha preso servizio in data 01/04/2008 come Ricercatore a tempo indeterminato per il SSD ING-IND/31 Elettrotecnica presso l'ex Facoltà di Ingegneria dell'Università degli Studi Roma Tre entrando a far parte dell'Unità di Elettrotecnica. Dal 2009 al 2015 ha conseguito, ogni anno, il titolo di Professore Aggregato per aver tenuto corsi assegnati per incarico dal Collegio didattico di Ingegneria Elettronica dell'Università Roma Tre. Nel 2014 ha conseguito l'idoneità all'Abilitazione Scientifica Nazionale (ASN), tornata 2013, Settore Concorsuale 09/E1 - SSD ING-IND/31 - II Fascia e dal 1/2/2016 è Professore Associato nel SSD ING-IND/31 Elettrotecnica presso il Dipartimento di Ingegneria – Sezione di Elettronica Applicata (SEA). È stato membro del Collegio dei Docenti della Sezione di Ingegneria dell'Elettronica Biomedica, dell'Elettromagnetismo e delle Telecomunicazioni della Scuola Dottorale di Ingegneria dell'Università degli Studi Roma Tre dal XXVI al XXVIII Ciclo, ultimo ciclo di attività della Scuola. È stato membro di tutti i Collegio dei Docenti del Dottorato in Elettronica Applicata, Dipartimento di Ingegneria, Università degli Studi Roma Tre, accreditati presso il MIUR. Nel 2017 ha conseguito l'idoneità all'Abilitazione Scientifica Nazionale (ASN) 2016-2018, secondo quadrimestre, Settore Concorsuale 09/E1 - SSD ING-IND/31 - I Fascia. Dal 1/3/2018 è Professore Ordinario nel SSD ING-IND/31 Elettrotecnica presso il Dipartimento di Ingegneria – Sezione di Elettronica Applicata (SEA). Francesco Riganti Fulginei ricerca e sviluppa sistemi intelligenti basati su algoritmi numerici e in particolari di machine learning. Tali algoritmi possono essere anche appositamente codificati per applicazioni specifiche come microcontrollori o sistemi mobili. La ricerca si estende anche alla gestione ottimizzata dell'energia da fonti rinnovabili e alla progettazione di sensori intelligenti (smart sensors). I prodotti generati spesso sono totalmente proprietari, così da generare dispositivi o librerie ottimizzate. Francesco Riganti Fulginei, inoltre, sviluppa algoritmi di intelligenza artificiale per applicazioni musicali, audio/video e artistiche. I risultati più significativi di queste attività sono stati presentati nel corso delle maggiori conferenze internazionali del settore quali COMPUMAG, OIPE, ISEF, AIM, etc..., anche patrocinate dall'IEEE, e sono apparsi su qualificate riviste internazionali, ricevendo apprezzamento e riconoscimento anche con premi internazionali. Francesco Riganti Fulginei è associate editor di prestigiose riviste internazionali inoltre è: Member of the Institute of Electrical and Electronics Engineers, Member of the IEEE Magnetic Society, Member of the CIRIAF Scientific Council, Member of International Compumag Society.