



UNIVERSITÀ
POLITECNICA
DELLE MARCHE

**UNIVERSITA' POLITECNICA DELLE MARCHE
FACOLTA' DI INGEGNERIA**

Corso di Laurea Magistrale in Ingegneria Meccanica

DIISM – Dipartimento di Ingegneria Industriale e Scienze Matematiche

**RETI NEURALI PER IL CONTROLLO PREDITTIVO DI UN EDIFICIO
COLLEGATO AD UN IMPIANTO DI TELERAFFRESCAMENTO**

**NEURAL NETWORKS FOR THE PREDICTIVE CONTROL OF A
BUILDING CONNECTED TO A DISTRICT COOLING SYSTEM**

Relatore:

Prof. Alessia Arteconi

Correlatore:

Ing. Gianluca Coccia

Tesi di Laurea di:

Matteo Cosci

Anno accademico 2019/2020

INDICE

INTRODUZIONE.....	6
1. CAPITOLO 1 - STATO DELL'ARTE.....	7
1.1 Controllo di sistemi multienergetici.....	7
1.2 Teleraffrescamento.....	9
2 CAPITOLO 2 – IL CONTROLLO MPC.....	11
2.1 Introduzione	11
2.2 Teoria del MPC.....	11
2.3 Funzione obiettivo.....	12
2.3.1 Orizzonte di previsione e orizzonte di controllo.....	13
2.3.2 Receding Horizon	13
2.3.3 Vincoli	14
2.4 Altre strategie di controllo	15
2.4.1 Controllo basato su regole (RBC).....	15
2.4.2 MPC centralizzato e decentralizzato.....	16
2.4.3 MPC stocastico (SMPC).....	16
2.5 Panoramica di studi recenti	17
3 CAPITOLO 3 – RETI NEURALI.....	19
3.1 Introduzione	19
3.2 Il neurone	19
3.3 Tipi di architettura della rete	21
3.3.1 Rete feedforward single layer.....	21
3.3.2 Rete feedforward multi-layer.....	22
3.3.3 Rete ricorrenti o feedback.....	22
3.4 Apprendimento.....	22
3.5 Generalizzazione	24
3.6 Reti neurali dinamiche	25
3.6.1 Reti neurali ricorrenti e ricorsive.....	25
3.6.2 Modello ARX	26
3.6.3 Rete NARX.....	27
4 CAPITOLO 4 – CREAZIONE DI UN MPC PER LA GESTIONE ENERGETICA DI UN EDIFICIO	30

4.1	Caso di studio	30
4.2	Creazione del modello.....	32
4.2.1	Modifica dello script e addestramento della rete	33
4.2.2	Analisi delle prestazioni della rete.....	34
4.3	Il controllo	36
4.4	Analisi dei risultati	40
5	CAPITOLO 5 – CONCLUSIONI	43
	APPENDICE 1	44
	APPENDICE 2	47
	BIBLIOGRAFIA	50

INDICE DELLE FIGURE

Figura 1 Tecnica del Receding Horizon [18].....	14
Figura 2: Esempio di un modello non lineare [36]	20
Figura 3: Una selezione di tipiche funzioni di attivazione: (a) lineare, (b) soglia, (c) soglia lineare e (d) sigmoide.[5]	21
Figura 4: rete feedforward multi-layer a due strati [36]	22
Figura 5: rete feedback [36].....	22
Figura 6: Schema di rete neurale [35].....	24
Figura 7:ottima generalizzaione (a), pessima generalizzazione (b) [36]	24
Figura 8: rete NARX con approssimazione feedforward. Immagine tratta dal sito Matlab.com	27
Figura 9: rete NARX in serie-parallelo. Immagine tratta dal sito Matlab.com	28
Figura 10:rete NARX in parallelo. Immagine tratta dal sito Matlab.com	29
Figura 11:Schema dell'impianto del sistema energetico del caso di studio, con particolare attenzione alla configurazione monoutente. L'energia termica fredda recuperata dal vaporizzatore L-CNG 260 viene utilizzata per soddisfare un DCS residenziale	31
Figura 12:Plot di confronto fra output e target (COOLING POWER) della rete neurale con 3 input e 1 output a 6 neuroni addestrata tramite LM.....	35
Figura 13: Plot di confronto output e target in un lasso temporale di 48 ore	35
Figura 14: Schema a blocchi dell'Algoritmo di minimizzazionebla	39
Figura 15: Controllo del caso di riferimento	41
Figura 16: Controllo MPC	41

NOMENCLATURA

ANN – artificial neural network

ARX – autoregressive with external input

AWHP – air-water heat pump

COP – Coefficiente di prestazione

CTRL_DC – Controllo district cooling system

CTRL_PHP – Controllo pompa di calore

DCS – district cooling system

DIISM - Dipartimento di Ingegneria Industriale e Scienze Matematiche

E_{GRID} – Energia elettrica prelevata dalla rete [kWh]

E_{HP} – Energia elettrica assorbita dalla pompa di calore [kWh]

E_{PV} – Energia elettrica prodotta da pannelli fotovoltaici [kWh]

FCU – Fan coil unity

FER – Fonti energia rinnovabile

HVAC – Heating Ventilation and Air Conditioning

LM - Levenberg-Marquardt

MPC – Model Predictive Control

NARX – Non-linear Autoregressive with external input

Q_{DC} – Energia elettrica prodotta da pannelli fotovoltaici [kWh]

Q_{ZONE} – Fabbisogno termico edificio [kWh]

RES - Renewable Energy Sources

RMSE – (Root Mean Squared Error)

RNN – Recurrent neural network

T_{SP} – Temperatura di setpoint [° C]

INTRODUZIONE

Alla base di questo studio vi è l'analisi dei sistemi di controllo e delle reti neurali, passando dall'analisi dei principi su cui sono fondati all'applicazione degli stessi. L'obiettivo è quello di porre l'attenzione sui modelli di controllo predittivo MPC (*model predictive control*) e sulle reti neurali ANN (*artificial neural network*) al fine di prevedere dapprima la domanda energetica di un edificio posto in un contesto multienergetico e successivamente, sulla base dei risultati ottenuti, effettuare il controllo dei vettori energetici dell'edificio.

Grazie all'esperienza vissuta durante il tirocinio mi è stato possibile approfondire e accrescere lo studio di tale tematica, sviluppando abilità e conoscenze in ambiti inizialmente a me sconosciuti.

Dapprima è stato effettuato uno studio attento ed approfondito sulle reti neurali, al fine di selezionare la migliore opzione da utilizzare come modello predittivo. Ovviamente è stato necessario alla base sviscerare il contesto multienergetico in cui tale sistema avrebbe operato. Tale rete poi è stata utilizzata dal sistema di controllo e implementata in esso.

La tesi si articola in 5 capitoli: nel primo capitolo viene fornita una presentazione dello stato dell'arte mediante l'analisi del controllo dei sistemi multienergetici, con particolare attenzione sugli impianti di teleraffrescamento. Il secondo è focalizzato sullo studio dei modelli di controllo predittivo, analizzandone la teoria alla base, le caratteristiche di cui sono dotati e ponendoli in analogia con altre strategie di controllo. Nel terzo capitolo si introducono i principi alla base delle reti neurali per poi passare nello specifico con le reti dinamiche NARX. Nel quarto capitolo si entra nello specifico analizzando in un primo momento il caso di studio per poi passare alla creazione di una vera e propria rete neurale e al suo addestramento sulla base delle richieste e infine al suo inserimento in un sistema di controllo per l'impianto. Nel quinto ed ultimo capitolo, si procede a commentare i risultati ottenuti dal modello di controllo predittivo creato esponendo gli elementi più rilevanti dell'indagine svolta.

1. CAPITOLO 1 - STATO DELL'ARTE

La gestione energetica per il raggiungimento del comfort degli edifici ha subito, nel corso degli anni, una continua evoluzione, motivata dalla ricerca dell'ottimizzazione dei consumi energetici e dal perseguimento delle stringenti normative volte alla salvaguardia dell'ambiente. Per tali ragioni sono nati i sistemi multi-energia, con lo scopo di unire efficientemente i mezzi e le risorse disponibili alla produzione di energia quali pompa di calore, solare, fotovoltaico, geotermico, cogenerazione, teleriscaldamento, teleraffrescamento e molti altri. L'unione e l'ottimizzazione di tali sistemi per garantire il comfort e il massimo risparmio energetico di un edificio posto in tale contesto multienergetico, nel caso di studio preso in analisi, è affidata a modelli di controllo predittivi (Model Predictive Control o più comunemente detti MPC). L'algoritmo di ottimizzazione di un MPC generalmente consiste in una complessa formulazione matematica, che può essere difficile dal punto di vista computazionale. L'obiettivo principale di questa tesi sarà quindi quello di creare un MPC di un edificio residenziale posto in un contesto multienergetico atto ad ottimizzare l'energia proveniente da un impianto di teleraffrescamento unitamente a quella generata da moduli fotovoltaici e attraverso sistemi di backup basati su pompe di calore aria-acqua a carico variabile, al fine di prevedere il fabbisogno necessario e ridurre al minimo l'energia elettrica prelevata dalla rete primaria nei mesi estivi.

1.1 Controllo di sistemi multienergetici

Nei sistemi multienergetici vengono combinate due o più fonti energetiche che alimentano lo stesso convertitore per sopperire alle limitazioni che contraddistinguono ciascuna fonte e ciascun convertitore. Spesso nei sistemi multi-energia una o più delle fonti energetiche è di tipo rinnovabile (FER- fonti di energia rinnovabile). L'impossibilità di conoscere l'esatta produzione di energia rinnovabile, che può essere solamente stimata senza certezza matematica, ha creato nel mercato la necessità di combinare le fonti rinnovabili con le fonti convenzionali, portando ad una richiesta multienergetica. Proprio l'irregolare possibilità di utilizzo delle fonti rinnovabili fa sì che questi sistemi diventino di difficile gestione. Risulta pertanto necessario l'impiego di modelli di calcolo capaci di

simulare questi complessi sistemi nell'ottica gestionale, con la creazione di strategie di funzionamento, al fine di ottimizzare il controllo in fase di esercizio [1]. In questo tipo di scenario, dove si cerca di abbassare il consumo di energia primaria prediligendo l'utilizzo di fonti di energia gratuita nel sistema, la flessibilità energetica acquista una notevole importanza. In edifici e distretti la flessibilità energetica è definita come funzione statica o dinamica e adatta al controllo [2-3]. La flessibilità degli edifici può essere ottenuta, ad esempio, sfruttando l'inerzia termica della struttura quando il costo dell'energia è più basso o totalmente gratuito. La regolazione della flessibilità può avvenire attraverso sistemi di controllo non predittivi, come avviene nel caso dei *rule based* che lavorano mediante regole, più o meno complesse, e strategie del tipo "if-else" per garantire gli obiettivi prefissati. Tuttavia, una migliore regolazione dei sistemi multienergetici può avvenire richiamando una tipologia di controlli, solitamente non lineari e utilizzati in impianti industriali, con un elevato numero di vincoli e variabili: i modelli predittivi di controllo (MPC). Gli MPC utilizzano un modello del processo per sviluppare un segnale di controllo, minimizzando una funzione obiettivo. Applicati in questo contesto, gli MPC permettono di aggiungere nella valutazione dei controlli un orizzonte temporale di previsione, con possibile impiego nelle condizioni metereologiche, nella disponibilità di fonti energetiche, nel prezzo e nella domanda di energia futura.

L'utilizzo degli MPC per trovare la migliore strategia di controllo comporta la costruzione di un modello fisico del sistema da controllare sul quale effettuare le simulazioni [4]. La rappresentazione di un sistema fisico composto da un edificio collegato ad un sistema multi-energia, può essere costruita su un modello *white*, *grey* o *black box*. Il modello *white box* è un'accurata rappresentazione fisica del sistema in studio, difficile da sviluppare ma che permette di ottenere ottimi risultati. Il modello *grey box* lega una struttura teorica parziale a dati esterni che ne completano il modello stesso. L'ultimo dei modelli è il *black box*, che prevede una rappresentazione matematica del sistema in cui ciascun parametro del modello non assume alcun valore fisico. Le reti neurali artificiali (Artificial neural network o ANN) sono la perfetta incarnazione dei modelli *black box*: sono modelli matematici che trasformano un insieme di variabili di input in un insieme di variabili di output [5]. Per avere una prima idea del funzionamento delle ANN è necessario creare una analogia con la struttura encefalica biologica dalla quale sono

ispirate. I dendriti di una rete biologica corrispondono agli input di una ANN, l'output svolge lo stesso compito di un assone biologico e i nodi di calcolo sono indicati come neuroni. Questi ultimi sono funzioni di attivazione che processano gli ingressi come funzioni lineari o non lineari producendo gli output corrispondenti. Prima di essere utilizzata, una ANN deve essere addestrata con un set di dati adeguato di input e target, con lo scopo di assegnare il giusto peso al file dei valori dei nodi. Con il crescente sviluppo delle tecnologie di analisi ed elaborazione dei dati, ora gli MPC basati sulle ANN hanno acquisito una maggiore applicazione rispetto al passato. Se utilizzati dunque nel campo dell'edilizia, aumenteranno le capacità di previsione dei sistemi multi-energia, migliorandone l'efficienza globale.

1.2 Teleraffrescamento

In una realtà dove la domanda di energia richiesta dagli edifici sta avendo un trend di crescita importante, occupando attualmente il 40% del consumo energetico mondiale, è fondamentale creare nuovi sistemi di raffreddamento che siano più efficienti delle attuali soluzioni, in modo tale da migliorare la sostenibilità delle città future. Un caso particolare tra le varie possibili fonti energetiche dei sistemi multienergia è costituito dal teleraffrescamento (DCS o district cooling). Un DCS, a differenza delle soluzioni individuali, è una soluzione centralizzata in grado di servire edifici residenziali, commerciali e industriali, soddisfacendo la domanda di raffreddamento per il condizionamento dell'aria, per la refrigerazione e per i processi industriali, producendo e distribuendo l'energia termica fredda richiesta [6]. Solitamente i DCS includono un sistema di generazione centrale, una rete di distribuzione, un punto di consegna ai clienti e un sistema di rifiuto del calore. La distribuzione del fluido termovettore viene eseguita con una piccola differenza di temperatura di progetto tra la temperatura di mandata fredda e la temperatura di ritorno più calda. Pertanto, i tubi di raffreddamento del DCS, se confrontati con quelli del teleriscaldamento, risultano di dimensioni maggiori. Le perdite di freddo sono molto piccole in Europa, dove le temperature medie annue del suolo sono quasi uguali alle temperature di distribuzione, mentre temperature del terreno più elevate, come quelle tropicali, richiedono un maggiore isolamento dei tubi. L'estremità finale della distribuzione negli edifici è gestita da sottostazioni collegate a scambiatori di calore.

Poiché la differenza di temperatura tra i tubi di alimentazione e di ritorno è molto ridotta, gli scambiatori utilizzati hanno lunghezze termiche elevate per non ridurre la capacità di trasferimento nelle reti di distribuzione. I DCS sono molto flessibili, pertanto possono essere ben integrati con FER, con energie di scarto, in sistemi di trigenerazione e di accumulo termico e nei cicli di refrigerazione ad assorbimento, riducendo notevolmente le emissioni di gas a effetto serra e il consumo di energia primaria.

2 CAPITOLO 2 – IL CONTROLLO MPC

2.1 Introduzione

Il *Model Predictive Control* (MPC) è una tipologia di controllo nata alla fine degli anni '70 che ha visto le sue prime applicazioni in ambito industriale per impianti di produzione di aziende chimiche e raffinerie. L'iniziale settore di applicazione fu scelto per la sua lenta dinamica dei processi che combaciava perfettamente con la bassa capacità computazionale di quei tempi. Nell'ultimo ventennio il repentino aumento della potenza di calcolo ha permesso agli MPC una larga diffusione, assumendo un ruolo fondamentale per molteplici tipologie di sistemi multivariabili. La più importante caratteristica di questa metodologia di controllo è l'abilità di programmazione delle azioni di controllo al fine di ottimizzare le prestazioni del sistema rispettando dei vincoli operativi in un intervallo di tempo futuro, denominato orizzonte di predizione [18].

In questo capitolo verrà mostrato nel dettaglio la creazione e i principi di funzionamento degli MPC con alcuni focus sul contesto della gestione e ottimizzazione energetica degli edifici.

2.2 Teoria del MPC

Gli MPC, come già anticipato, fanno uso di un modello del sistema basato sulla fisica (*white box*) o basato sui dati (*black box*) per prevedere l'output del sistema stesso. I modelli basati sulla fisica si fondano sulla conoscenza del processo, i parametri che possono essere determinati dalla documentazione del produttore e l'applicazione delle tecniche di stima dei parametri dei dati di processo misurati. I modelli basati sui dati invece adattano funzioni matematiche lineari e non ai dati misurati; ne sono un esempio le ANN, che verranno approfondite nel capitolo 3 di questo scritto. In ogni caso, per sviluppare modelli di buona qualità, i dati dovrebbero avere un'elevata precisione, un basso rumore e un'adeguata risoluzione temporale per catturare correttamente la dinamica del processo. Per i processi in rapido movimento la velocità di campionamento dovrebbe essere più elevata rispetto a quella dei processi a movimento lento. Dopo lo sviluppo è necessaria la convalida del modello stesso per verificarne l'accuratezza. La validazione

può essere effettuata confrontando gli output del modello con misurazioni note, con soluzioni analitiche di un problema noto o con i risultati d altri software di modellazione. Infine, la deviazione tra i risultati delle previsioni e i dati misurati può essere calcolata mediante l'errore assoluto (AE, differenza tra il valore massimo misurato e il valore esatto), la radice dell'errore quadratico medio (RMSE, radice quadrata della discrepanza quadratica media fra i valori dei dati osservati ed i valori dei dati stimati), la deviazione standard dell'errore assoluto (StdAE, una stima della variabilità dell'errore assoluto) e molti altri [19].

$$\begin{aligned}
 \text{AE:} \quad & E_{ass} = |V_{misurato} - V_{esatto}| \\
 \text{RMSE:} \quad & RMSE = \sqrt{\left(\frac{1}{n} \sum_{j=1}^n (y_j - \hat{y}_j)^2\right)} \\
 \text{StdAE:} \quad & \sigma = \sqrt{\frac{\sum_{j=1}^N (x_j - \mu_j)^2}{N}}
 \end{aligned}$$

La creazione del modello è necessaria per predire gli stati futuri del sistema e generare un'azione di controllo ottimale che minimizza una certa *funzione obiettivo* su un orizzonte temporale finito, in presenza di vincoli e disturbi.

2.3 Funzione obiettivo

In un problema di controllo ottimo la funzione obiettivo, o di costo, è la quantità da massimizzare o minimizzare, espressa come funzione delle variabili decisionali. La funzione costo descrive quindi il comportamento desiderato e generalmente ha due scopi. Il primo fra questi è la stabilità: è comune scegliere la funzione di costo in modo che il costo ottimale costituisca una funzione di Lyapunov e quindi garantire stabilità (capacità di stabilizzare il sistema dinamico in seguito a perturbazioni in prossimità di un punto di equilibrio). Il secondo è che il costo deve descrivere generalmente uno o più obiettivi prestazionali, avendo quindi la possibilità di specificare la preferenza verso un comportamento particolare, che può essere ad es. quello di minimizzare l'energia o massimizzare il comfort.

In letteratura si trovano moltissimi esempi di funzione di costo, come il consumo energetico dell'intero edificio, l'efficienza complessiva del sistema, il comfort termico degli occupanti, il setpoint della temperatura interna e molto altro [9].

2.3.1 Orizzonte di previsione e orizzonte di controllo

L'orizzonte di previsione si riferisce al periodo di tempo per il quale l'uscita del sistema viene calcolata dall'MPC, mentre l'orizzonte di controllo indica il periodo di tempo per il quale viene calcolato il segnale di controllo. Inoltre, il passo temporale (o tempo di campionamento del controllo) è il tempo durante il quale il segnale di controllo rimane invariato [10].

2.3.2 Receding Horizon

L'azione di controllo viene quindi calcolata ottimizzando su un orizzonte di tempo finito l'indice di prestazione desiderato. Si ottiene così una sequenza di controllo ad anello aperto, definita nell'orizzonte di previsione, di cui solo la prima viene effettivamente applicata e all'istante di tempo successivo si ripete il procedimento. Questa tecnica è chiamata Receding Horizon o orizzonte temporale e viene applicata come segue. Ad ogni istante k si considera un orizzonte temporale di previsione di dimensione N , con estensione da k a $k + N$, dove attraverso il modello vengono predette le uscite nell'orizzonte così definito. A questo punto i segnali di controllo saranno calcolati ottimizzando una specifica funzione di controllo affinché il processo rimanga il più vicino possibile alla traiettoria che definisce il riferimento da inseguire. Tuttavia, solamente il primo elemento della sequenza dei segnali di controllo verrà utilizzato, mentre tutti gli altri saranno scartati e, al successivo istante temporale $k + 1$, il nuovo orizzonte temporale passerà da $(k, k + N)$ a $(k + 1, k + 1 + N)$ per poi ripetere la procedura descritta per tutti i successivi istanti [18].

Dalla *Figura 1* è evidente lo spostamento in avanti dell'orizzonte temporale ad ogni iterazione. Così facendo si acquisisce una sequenza di controllo che sarà diversa dalla precedente, garantendo una certa solidità contro eventuali errori di modellazione e disturbi.

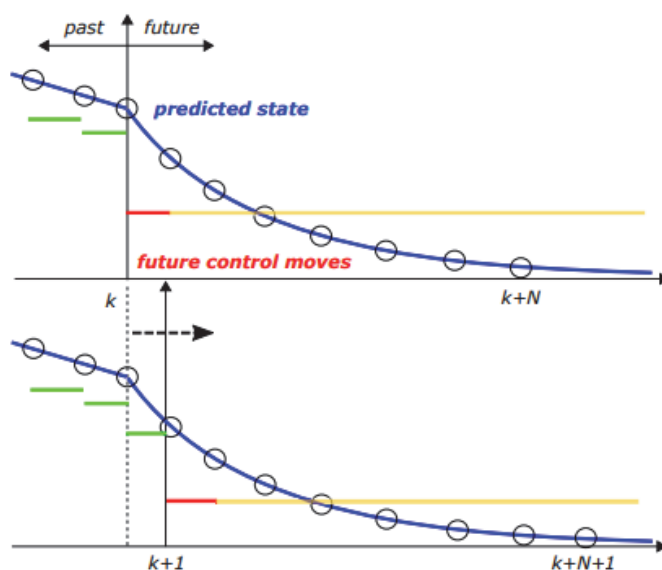


Figura 1 Tecnica del Receding Horizon [18]

2.3.3 Vincoli

La capacità di specificare i vincoli nella formulazione di un MPC è uno dei punti di forza di tale sistema. Nella pratica esistono un gran numero di tipologie di vincoli utilizzabili, ma di seguito andremo ad analizzare i più comuni e adatti per la costruzione del controllo climatico di un edificio. Il vincolo lineare è uno dei più comuni e viene utilizzato per porre limiti superiori e/o inferiori sulle variabili. Questa tipologia è la più facile da gestire quando si risolvono problemi di ottimizzazione. Il vincolo quadratico convesso si utilizza per legare una variabile all'interno di un ellissoide; nella costruzione del controllo climatico questo tipo di vincolo sorgerebbe, ad es., quando si limita la somma dell'energia in ingresso tra più attuatori. Il vincolo di probabilità si usa quando nel problema è coinvolta l'incertezza così da formulare che la sua condizione deve essere soddisfatta con una probabilità predefinita. I vincoli conici del secondo ordine hanno il nome conico perché la loro regione possibile di applicazione del vincolo ha la forma di un cono; in circostanze particolari possono derivare da riformulazioni di vincoli casuali. Il Vincolo commutato comprende un insieme di vincoli, dove ognuno è rilevante solo se viene soddisfatta una condizione predefinita. Questo è un tipo comune di vincolo nei sistemi ibridi, vale a dire i sistemi che presentano un comportamento temporale sia continuo che discreto.

In ultimo, il vincolo non lineare che comprende qualsiasi tipo di vincolo che non rientra nelle categorie di cui sopra. In generale, è molto difficile gestire questo tipo di vincolo quando si risolvono problemi di ottimizzazione [10].

Per approfondire la comprensione dei tipi di vincoli nello sviluppo degli MPC, vengono descritti esempi selezionati dalla letteratura. Per il controllo della temperatura e dell'umidità di una zona [11], i vincoli sono stati posti sulla velocità del ventilatore dell'aria di mandata per rimanere tra “0,1 e 0,75” del valore nominale e sull'apertura della valvola dell'acqua refrigerata per rimanere tra “0,1 e 1”. Per il controllo della temperatura ambiente nel riferimento [12], sono stati posti dei limiti al flusso di calore di mandata e alla temperatura interna. Il flusso di calore minimo era limitato a zero, ma il suo massimo rimaneva non vincolato. Per la generazione di un profilo di set point di temperatura ottimale per lo stoccaggio di acqua nel serbatoio nel rif. [13], i valori ammissibili del setpoint della temperatura del serbatoio erano vincolati tra “30° C e 55° C”.

2.4 Altre strategie di controllo

In questa sezione vengono presentate tre significative strategie di controllo applicabili alla gestione climatica di un edificio: *Rule-Based Control (RBC)*, *MPC centralizzato e decentralizzato* e *Stochastic MPC (SMPC)*.

2.4.1 Controllo basato su regole (RBC)

La metodologia di controllo *rule based* lavora mediante regole, più o meno semplici, e attraverso strategie “*if-else*”. È ancora molto diffusa e, in molte situazioni, risulta la più adeguata alla gestione energetica degli edifici. Infatti, la maggior parte delle pompe di calore al giorno d'oggi sono controllate da modelli rule based. Nell'ipotesi in cui sia presente un impianto fotovoltaico posto in alimentazione ad una pompa di calore, il controllo di quest'ultima viene applicato massimizzando il consumo di energia fotovoltaica disponibile. I limiti di questa implementazione [8] emergono dal mancato inserimento nel controllo della pompa di calore della futura domanda termica o la disponibilità di elettricità FV del giorno seguente. Ciò potrebbe portare ad alte temperature di conservazione e perdite evitabili per un lungo periodo, poiché viene

immagazzinato più calore di quanto effettivamente necessario per il giorno successivo con conseguente violazione del comfort e perdita di efficienza. Tutto ciò dimostra come difficilmente si possono ottenere ottimi risultati senza tener conto delle previsioni. D'altro canto, i controlli *rule based* richiedono una progettazione delle regole che può essere relativamente semplice mostrando ancora buone prestazioni. Inoltre, il calcolo delle azioni di controllo richiede meno risorse computazionali e, in alcuni casi i controlli basati su regole sono l'unico modo per rispondere celermente a condizioni critiche del sistema.

2.4.2 MPC centralizzato e decentralizzato

In un edificio costituito da un elevato numero di appartamenti il modello rappresenta un sistema interconnesso di sottoinsiemi afflitti da interazioni termiche. Uno schema di controllo MPC centralizzato determina una azione di controllo che ottimizza le prestazioni del sistema nella sua totalità. Tuttavia, la considerevole dimensione del modello usato per il controllore centralizzato potrebbe richiedere elevati sforzi computazionali. Uno schema di controllo alternativo è quello decentralizzato: prevede che i sottoinsiemi siano separati e indipendenti tra loro generando diversi schemi di controllo, uno per ogni sottoinsieme, che lavoreranno simultaneamente. In questo caso le azioni di controllo che ottimizzano le prestazioni dei singoli sottoinsiemi si ignorano completamente e, quindi, le interconnessioni tra gli stessi sono trattate come disturbi esterni sconosciuti [14]. Sebbene non si raggiunga l'accuratezza di un MPC centralizzato, i risultati di alcune pubblicazioni [15, 16] mostrano che il controllo predittivo del modello decentralizzato (DMPC) può fornire una soluzione quasi ottimale con meno sforzo computazionale.

2.4.3 MPC stocastico (SMPC)

Gli SMPC sono degli innovativi algoritmi di controllo predittivo volti a sfruttare la natura stocastica dell'incertezza del modello attraverso la sua natura statistica. In questa ottica, i rigidi vincoli sulle variabili di sistema devono essere riformulati come stocastici, consentendo al sistema controllato di violarli in termini probabilistici precedente definiti.

Così facendo, è possibile considerare anche disturbi e/o incertezze illimitati, ad esempio nel caso in cui siano caratterizzati da una distribuzione gaussiana [17].

La formulazione SMPC si adatta bene allo scopo di costruire il controllo climatico di un edificio. Ad es. con gli SMPC è possibile tener conto direttamente dell'incertezza nelle previsioni meteorologiche, consente di formulare i cosiddetti vincoli di probabilità, vale a dire di applicare i vincoli da soddisfare con una probabilità predefinita, allo stesso modo come richiesto dalle norme di costruzione per i vincoli di temperatura ambiente.

2.5 Panoramica di studi recenti

Di seguito, verranno riportati alcune applicazioni degli MPC legate al settore dell'edilizia. Nel 2011 Široký et al. [21] hanno riportato un test di un sistema MPC impiegato in un edificio universitario per il controllo di sistemi HVAC, ottenendo un risparmio energetico del 17-24% rispetto al controllo esistente. Reynolds et al. [22] hanno sviluppato un controller MPC utilizzando un modello di edificio basato su ANN per la pianificazione di set point di riscaldamento in un edificio. Le loro simulazioni mostrano che l'approccio MPC permette una riduzione di energia del 27% rispetto al controllo convenzionale. Nel 2017, un controllo basato su MPC è stato proposto da Afram e Janabi-Sharifi [23] per trasferire la richiesta di riscaldamento e raffreddamento di un edificio residenziale lontano dalle ore di punta. Dati sperimentali hanno mostrato che l'impiego di set-point a temperatura variabile calcolati dall'MPC hanno comportato un risparmio dei costi del 16% rispetto ai set-point fissi. In una successiva recensione [24], gli stessi autori hanno poi analizzato la letteratura relativa alle MPC basate su ANN utilizzate nell'ottimizzazione dei sistemi HVAC e hanno riportato il caso di studio. L' MPC basato sulla ANN ha generato set-point della temperatura dinamica dell'aria di zona e dell'acqua del serbatoio di accumulo, con conseguente riduzione dei costi operativi che vanno dal "6% al 73%" rispetto a un set-point fisso.

Anche la misurazione dell'occupazione di un edificio può essere utilizzata per risparmiare energia nei periodi di minore affluenza. Infatti, per garantire il comfort all'arrivo di un flusso di persone all'interno dell'edificio, è necessario l'utilizzo di un MPC con i relativi dati di previsione dell'occupazione. In [20] la misurazione dell'occupazione in un edificio

multi-zona viene utilizzata per ridurre al minimo il consumo di energia pur mantenendo la qualità dell'aria e il comfort degli occupanti. In questo studio, il comfort ambientale, il consumo di energia e la qualità dell'aria interna sono stati utilizzati come funzione di costo. Questa simulazione mostra un risparmio energetico fino al 12% rispetto ad un controllo *rule based*. I sistemi di controllo predittivi sono stati anche utilizzati per effettuare un'ottimizzazione energetica online di un edificio residenziale con sistema di riscaldamento elettrico a pavimento [25]. Due sono i sistemi di controllo considerati: un MPC con set-point di temperatura costante e un MPC funzionante con un ottimizzatore di set-point in grado di ridurre al minimo la quantità di energia utilizzata. La prima strategia ha portato a una riduzione di circa 1430 kWh durante la stagione di riscaldamento, mentre la seconda la strategia ha consentito un'ulteriore riduzione di 300 kWh in un anno. Tenendo conto dei DCS gestiti con MPC e altri controlli simili, nel 2019 Cox et al. [26] hanno proposto un MPC basato su ANN accoppiato con un ottimizzatore di algoritmi per determinare la strategia di controllo di un deposito di ghiaccio installato in un DCS. I risultati mostrano che il controllo ottimale può ridurre i costi operativi del DCS di circa il 16% e 13% rispettivamente in base al tempo di utilizzo e al prezzo in tempo reale.

3 CAPITOLO 3 – RETI NEURALI

Gli MPC necessitano di un modello che riproduca il comportamento del sistema considerato per poter predire. La rappresentazione di tale modello può avere diverse nature. In questo capitolo verrà fatto un approfondimento sui modelli black box, mostrando brevemente i principi alla base delle reti neurali, con un focus sulla tipologia di rete che verrà impiegata nel caso di studio, ovvero le reti dinamiche.

3.1 Introduzione

Le reti neurali racchiudono un'ampia varietà di potenti tecniche per risolvere problemi relativi al riconoscimento, all'analisi dei dati e al loro controllo. Si contraddistinguono per la loro velocità di elaborazione e per la loro capacità di apprendimento, potendo arrivare alla soluzione del problema semplicemente da una serie di esempi. Il loro funzionamento si ispira ai processi biologici di una struttura encefalica, caratterizzata da milioni di unità computazionali (neuroni) in grado di eseguire una somma pesata a partire da un elevato numero di connessioni pesate (sinapsi) tra le unità. Questi sistemi posseggono un'elevata capacità di apprendimento, raggiunta attraverso la modifica dei pesi delle connessioni, dal momento che tali processi non solo risultano essere altamente paralleli, non lineari, adattivi, addestrabili, ma anche tolleranti agli errori, in quanto la memorizzazione avviene in modo diffuso. Grazie a queste caratteristiche, le reti neurali sono capaci di produrre output ragionevoli con input mai incontrati prima durante l'apprendimento.

3.2 Il neurone

La costruzione di una rete neurale prevede l'utilizzo di una unità di calcolo che viene rappresentata da uno o più neuroni. Il neurone, infatti, si occupa di processare i dati fornitogli e racchiude in se tre elementi: un insieme di connessioni arbitrariamente pesate, un sommatore che somma i segnali in input, opportunamente pesati dalle precedenti sinapsi, generando in uscita una combinazione lineare degli input e infine una funzione di

attivazione che limita l'ampiezza dell'output in uscita dal neurone. Possiamo matematicamente descrivere un neurone k attraverso le seguenti equazioni:

$$u_k = \sum_{j=1}^m w_{kj} \cdot x_j + b_k \quad (1)$$

$$y_k = \varphi(u_k) \quad (2)$$

E graficamente:




Figura 2: Esempio di un modello non lineare [36]

dove:

- x_j sono i segnali sinaptici associati agli input in ingresso al neurone k;
- w_{kj} sono i vettori dei pesi del neurone k;
- u_k è la combinazione lineare degli input nel neurone k;
- b_k è il valore soglia del neurone k;
- φ è la funzione di attivazione;
- y_k è l'output generato dal neurone k.

Il segnale x_j all'ingresso j viene prima moltiplicato per un parametro w_{kj} , noto come peso, e viene quindi aggiunto a tutti gli altri segnali di input già pesati per fornire un input totale (1). Inoltre, il valore b_k (bias) rappresenta un valore di soglia e può essere considerato come un caso speciale di peso che deriva da un input aggiuntivo che può assumere valori

del tipo $+1$ 0 -1 . L'output y_k viene quindi generato operando su u_k mediante una funzione di attivazione non lineare φ [5]. Alcune funzioni di attivazione sono mostrate nella Figura 3.




Figura 3: Una selezione di tipiche funzioni di attivazione: (a) lineare, (b) soglia, (c) soglia lineare e (d) sigmoide.[5]

3.3 Tipi di architettura della rete

Nell'analisi delle varie architetture è comune classificare gli algoritmi di apprendimento in 3 classi.

3.3.1 Rete feedforward single layer

All'interno della rete neurale sono presenti solamente i nodi di input con un singolo strato di neuroni. Il segnale si propaga in avanti dal layer di input a quello di output dove non sono presenti connessioni di alcun tipo.




Figura 3: rete feedforward single layer [36]

3.3.2 Rete feedforward multi-layer

In questa configurazione sono presenti in entrambi gli strati di input ed output uno o più strati di *hidden layers* (neuroni nascosti). Ogni strato è connesso con il precedente e con il successivo e il segnale si propaga in avanti. Rispetto al single layer, qui le interazioni aumentano fornendo alla rete una prospettiva più ampia.




Figura 4: rete feedforward multi-layer a due strati [36]

3.3.3 Rete ricorrenti o feedback

A differenza della precedente, questa tipologia ha anche la caratteristica di essere ciclica.




Figura 5: rete feedback [36]

3.4 Apprendimento

Una rete neurale feedforward può essere considerata come una funzione matematica non lineare che trasforma una serie di variabili di input in una serie di variabili di output. La forma precisa della trasformazione è regolata da un insieme di parametri chiamati pesi w

cui valori possono essere determinati sulla base di un insieme di esempi della mappatura richiesta. Il processo di determinazione di questi valori di parametri viene spesso chiamato apprendimento e può risultare impegnativo dal punto di vista computazionale. Una volta fissati i pesi, tuttavia, i nuovi dati possono essere elaborati dalla rete molto rapidamente.

Il processo che consente di adattare i parametri liberi di una rete neurale all'ambiente in cui è inserita è definito apprendimento. Le principali metodologie di apprendimento sono [27]: apprendimento supervisionato dove la rete impara la relazione tra input e output tramite esempi degli stessi; l'apprendimento non supervisionato ha lo scopo di fornire una struttura logica ad un set di dati in ingresso senza avere a disposizione gli output; nell'apprendimento per rinforzo il sistema si relaziona con un ambiente dinamico ed è capace di imparare anche dagli errori.

Esiste inoltre un altro importante algoritmo di apprendimento molto utilizzato: l'algoritmo di retro-propagazione. Esso confronta il valore di output della rete con il valore desiderato (target) e calcola la differenza tra i due determinando l'errore. Con questa valutazione l'algoritmo modifica i pesi sinaptici della rete neurale indirizzando progressivamente gli output verso i valori desiderati. Considerando una rete neurale composta da un singolo nodo e un singolo input X , il sistema ha come obiettivo quello di raggiungere un certo livello di output, denominato Y_{TARGET} . Alla fine di ogni ciclo, l'algoritmo mette a confronto il risultato ottenuto Y con il risultato desiderato Y_{TARGET} e calcola un errore " $Y_{TARGET}-Y$ ". Il feedback permette all'algoritmo di utilizzare l'errore per regolare il peso sinaptico adeguato e dunque eseguire una nuova iterazione (retro-propagazione). La regolazione di tale peso sinaptico è ricavata dall'errore e da due parametri del sistema: il tasso di apprendimento e il momento (entrambi variano tra 0 e 1). Per quanto riguarda il primo, più esso è vicino al valore massimo, più veloce è il processo di apprendimento, poiché le variazioni da apportare sul peso sinaptico sono maggiori. Bisogna fare attenzione però, poiché un tasso di apprendimento molto elevato può essere controproducente dato che aumenta anche il rischio di variazioni/oscillazioni del risultato e, quindi, l'instabilità di tutto il sistema. Per ridurre tali irregolarità e favorire la convergenza dei risultati, nella formula di regolazione del peso sinaptico si utilizza un altro parametro "a", chiamato momento, anche esso compreso tra zero e uno. Dato che la

complessità dell'algoritmo cresce proporzionalmente con quella della rete neurale, è bene prestare attenzione a due possibili fenomeni: l'*underfitting* (sotto-adattamento) e l'*overfitting* (sovrà-adattamento). Nel primo caso la rete è composta da pochi neuroni e l'apprendimento della rete risulta inefficace mentre nel secondo caso la rete è composta da troppi neuroni e rendendo più complicato il processo di generalizzazione.




Figura 6: Schema di rete neurale [35]

3.5 Generalizzazione

La generalizzazione è la capacità di restituire predizioni attendibili quando si inseriscono nuovi dati in input che non sono stati utilizzati per l'addestramento. Buoni risultati si ottengono quando all'ingresso vengono forniti nuovi input che si discostano lievemente dagli esempi usati in fase di addestramento e la rete produce mappature input/output corrette.




Figura 7: ottima generalizzazione (a), pessima generalizzazione (b) [36]

3.6 Reti neurali dinamiche

Il bisogno di applicare la componente temporale ai sistemi di reti neurali ha generato una nuova famiglia di reti denominate dinamiche. L'obiettivo è creare una trasformazione che varia nel tempo, in grado di associare ad una funzione $x(t): \{t_0, t_1\} \geq R^n$ (3), chiamata pattern spazio-temporale e che lega ad ogni istante t un punto nello spazio n -dimensionale di input, una funzione di output denominata $y(t)$. La programmazione e l'analisi di un pattern spazio-temporale avviene tramite 3 metodologie:

- La creazione di una raffigurazione spaziale di dati temporali
- Impostando dei ritardi nei neuroni e nelle connessioni tra di essi (time-delay)
- utilizzando neuroni con particolari tipologie di attivazione che sommano gli input nel tempo

Tuttavia, solo l'unione delle 3 permette di raggiungere buoni risultati. Infatti, trasformare la totalità dei dati di output in una sequenza di dati, crea dei problemi al livello di memoria della rete. Quando arriva un nuovo input i dati precedenti vengono eliminati e così si prosegue via via facendo. Ciò comporta inevitabilmente che la rete conserva memoria del passato solo nei neuroni intermedi.

Introducendo allora il concetto del "time-delay" nelle reti l'informazione passa da sinistra a destra attraverso una catena di nodi e l'informazione successiva ripete tale azione.

Ciò comporta che la lunghezza della catena di nodi influenza l'intervallo in cui si effettua il campionamento dell'informazione. Se introduco un ritardo in una architettura che ha stati di stabilità ed è priva di time-delay ottengo solo oscillazioni ed incertezze, ma se al contrario trasmetto il ritardo attraverso le connessioni, l'informazione per un determinato periodo rimane in un certo stato prima che scatti l'informazione successiva. Queste reti possono essere dotate di breve o lunga memoria.

3.6.1 Reti neurali ricorrenti e ricorsive

Nelle reti neurali ricorrenti le connessioni tra i nodi formano una sorta di grafico orientato verso una direzione, ricordando il passato e quindi le sue decisioni sono influenzate da

quanto appreso. Le reti neurali ricorsive sono invece una forma più generale delle ricorrenti e sono in grado di analizzare gli input non necessariamente in modo sequenziale.

3.6.2 Modello ARX

Per esprimere la relazione tra l'ingresso, $u(t)$, l'uscita $y(t)$ e il rumore $e(t)$ un modello polinomiale usa una nozione generalizzata di funzioni di trasferimento attraverso l'equazione:

$$A(q)y(t) = \sum_{i=1}^{nu} \frac{B_i(q)}{F_i(q)} u_i(t - nk_i) + \frac{C(q)}{D(q)} e(t) \quad (4)$$

Le variabili A, B, C, D e F sono polinomi espressi nell'operatore time-shift q^{-1} .

u_i è l' i -esimo ingresso, nu è il numero totale di ingressi e nk_i è l' i -esimo ritardo di ingresso che caratterizza il ritardo di trasporto. Si presume che la varianza del rumore bianco $e(t)$ sia λ .

In pratica, non tutti i polinomi sono contemporaneamente attivi. Spesso vengono impiegate forme più semplici, tra tali forme troviamo le ARX.

La loro equazione polinomiale è la seguente:

$$A(q)y(t) = \sum_{i=1}^{nu} B_i(q)u_i(t - nk_i) + e(t) \quad (5)$$

Il modello del rumore è $\frac{1}{A}$ ed esso è accoppiato al modello della dinamica. L'ARX non consente di modellare il rumore e la dinamica in maniera indipendente una dall'altra. Utilizzare un modello ARX ci permette di ottenere un modello semplice con buoni rapporti segnale-rumore.

3.6.3 Rete NARX

La rete autoregressiva non lineare con input esterni (Non Linear Autoregressive network with exogenous inputs o NARX) è una rete dinamica ricorrente, con connessioni di feedback che racchiudono diversi strati della rete. Il modello NARX si basa sul modello lineare ARX, comunemente utilizzato nella modellazione di serie storiche. L'equazione che definisce il modello NARX è:

$$y(t) = f(y(t - 1), y(t - 2), \dots, y(t - n_y), u(t - 1), u(t - 2), \dots, u(t - n_u)) \quad (6)$$

Qui il valore successivo al segnale $y(t)$ viene regredito su valori precedenti del segnale di output e su valori precedenti di un segnale di input esterno.

È possibile implementare il modello NARX utilizzando una rete neurale feedforward per approssimare la funzione F . Di seguito è mostrato un diagramma della rete risultante, dove per l'approssimazione viene utilizzata una rete feedforward a due strati. Questa implementazione consente anche un modello ARX vettoriale, in cui input e output possono essere multidimensionali.

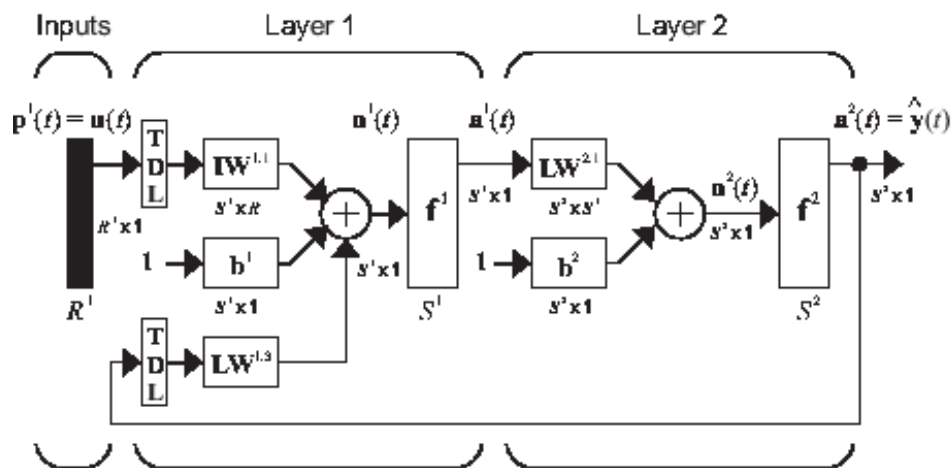


Figura 8: rete NARX con approssimazione feedforward. Immagine tratta dal sito Matlab.com

Le reti neurali NARX come tutte le reti dinamiche non lineari possono avere due diverse configurazioni, una denominata “in serie-parallelo” ed una denominata “in parallelo”. Il

modello dinamico non lineare può essere usato in due differenti configurazioni per ottenere due scopi ben diversi. Il primo è la predizione: in base agli input e agli output di un processo, il modello predice uno o più step futuri, e lo schema ad esso associato è il modello serie-parallelo (è uno schema “ad anello aperto” in quanto è necessario conoscere al posto di utilizzare la retroazione dell’uscita). Il secondo scopo riguarda la simulazione: soltanto in base all’input si può prevedere l’output futuro, ad esso corrisponde il modello parallelo (in questo caso non è richiesto di conoscere l’output desiderato). Solitamente le prestazioni nel caso del modello parallelo sono inferiori a quelle del modello serie-parallelo. Solitamente si addestra una rete in configurazione serie-parallelo e poi chiudere l’anello per generare il modello parallelo.

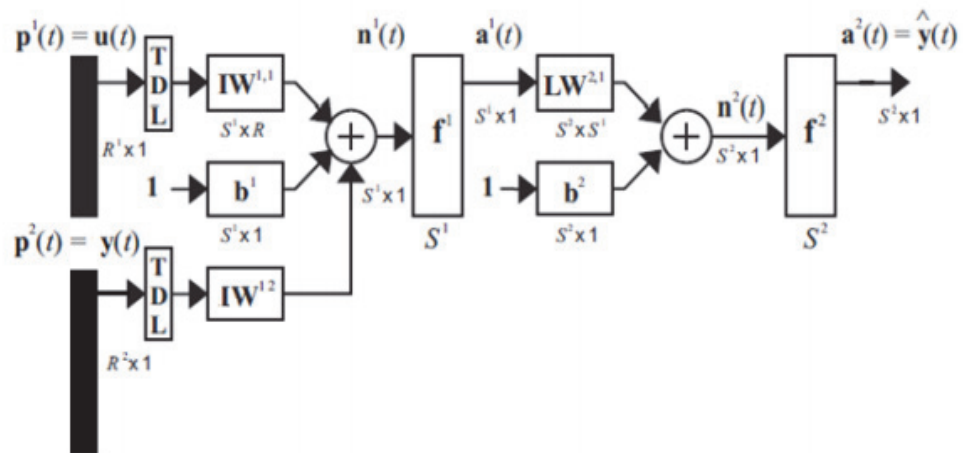


Figura 9: rete NARX in serie-parallelo. Immagine tratta dal sito Matlab.com

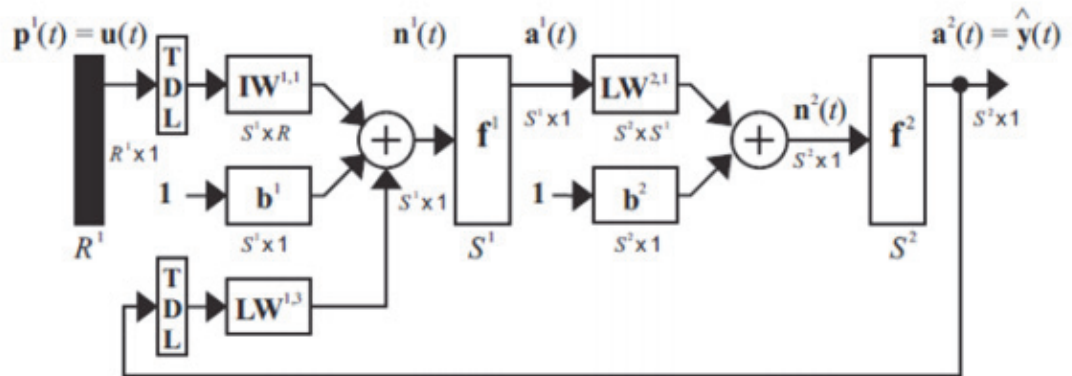


Figura 10: rete NARX in parallelo. Immagine tratta dal sito Matlab.com

4 CAPITOLO 4 – CREAZIONE DI UN MPC PER LA GESTIONE ENERGETICA DI UN EDIFICIO

In questo capitolo verrà descritto nel dettaglio il lavoro svolto durante il tirocinio, ossia la creazione di un MPC basato su una rete neurale, per gestire la domanda di energia “fredda” di un edificio nei mesi estivi attraverso un sistema multi-energia con l’obiettivo finale di minimizzare la spesa energetica. Tale sistema è composto da un impianto di teleraffrescamento distrettuale (DCS), moduli fotovoltaici e sistemi di backup basati su pompe di calore aria-acqua a carico variabile (AHWP). La prima parte sarà focalizzata sulla descrizione del caso di studio e la creazione del modello dell’edificio con riferimento alla tesi [29] del collega ing. Luca Carboni. Nella seconda parte la trattazione si concentrerà sull’ottimizzazione e sulla realizzazione del controllo di tale modello.

4.1 Caso di studio

Il caso di studio è costituito da un edificio facente parte di un quartiere residenziale di 8 utenti monofamiliari situati a Roma, in Italia (41 ° 55 'N, 12 ° 31' E). Le caratteristiche termiche dell’involucro dell’edificio sono state estrapolate dal progetto Tabula [30], considerando i dati forniti per le migliori prestazioni energetiche (sezione di Tabula dal 2006 in poi). Ciascuno degli 8 edifici sono stati modellati come una singola zona termica contraddistinta da un coefficiente di perdita globale ($0,38 \text{ W m}^{-2} \text{ K}^{-1}$) e una capacità termica totale (55 MJ K^{-1}) [31]. Il numero di utenti inclusi nel vicinato è stato determinato tramite una stima del carico di raffreddamento di progetto per singolo utente [32]: la domanda di picco è stata stimata in 6.7 kWt, con una condizione di comfort interno di 26° C e una umidità relativa del 50%. Sulla base di questi dati, il numero di consumatori collegati al DCS è stato selezionato per garantire la soddisfazione del picco di richiesta di potenza di raffreddamento per almeno 2 ore a giorno (tra le 17:00 e le 18:00) e tramite il solo DCS, per tutti gli utenti contemporaneamente. Il collegamento tra la rete DCS e ogni utente avviene mediante uno scambiatore di calore (“use heat exchanger”, *Figura 1*, pagina successiva) dove il fluido termovettore del DCS raffredda acqua fino a una temperatura di 7° C, nel caso in cui la richiesta di picco di raffreddamento sia pienamente

soddisfatta. Se l'energia termica fredda fornita dal DCS non soddisfa i requisiti stabiliti, la richiesta di raffreddamento viene coperta da sistemi di backup installati da ogni singolo utente.

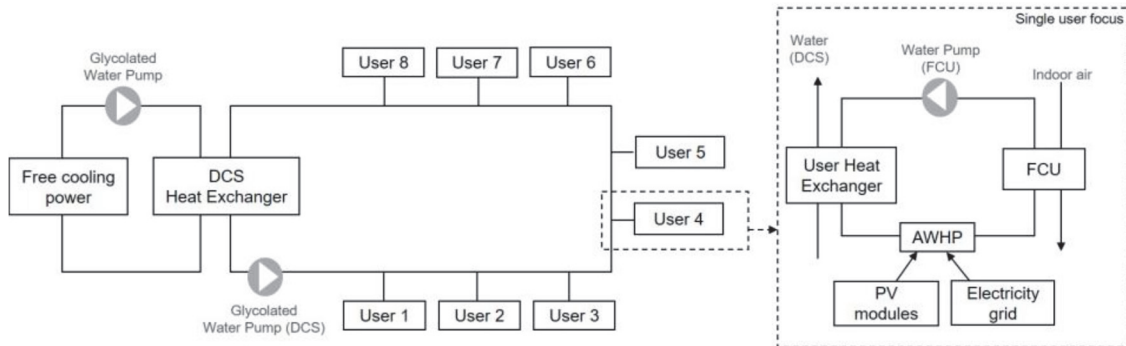


Figura 11: Schema dell'impianto del sistema energetico del caso di studio, con particolare attenzione alla configurazione monoutente. L'energia termica fredda recuperata dal vaporizzatore L-CNG 260 viene utilizzata per soddisfare un DCS residenziale

Questi sistemi di backup sono composti da pompe di calore aria-acqua (AWHP) a carico variabile e il loro coefficiente di prestazione (COP) è una funzione della temperatura esterna e della temperatura del fluido di trasferimento del calore [33]. Ogni AWHP è collegato in serie con il corrispondente scambiatore di calore, come mostrato nella Figura 9, e l'attivazione avviene da un controller impostato sul limite di comfort della temperatura interna ($25 + 0,5 \text{ }^\circ\text{C}$). Le unità fan coil (FCU) sono state utilizzate per trasferire la potenza di raffreddamento disponibile dal circuito dell'acqua all'aria interna. L'energia utile al funzionamento degli AWHP può essere prelevata dall'elettricità raccolta dalla rete o dai moduli fotovoltaici installati sul tetto di ciascun edificio. Ogni impianto fotovoltaico è composto da 3 array e ogni di essi comprende 10 pannelli in silicio policristallino collegati in serie con una potenza nominale di 250 We (caratteristiche fornite nei fogli di dati commerciali [34]).

Il DCS e il quartiere residenziale sono stati modellati in un ambiente di simulazione TRNSYS (programma di simulazione utilizzato principalmente nei settori dell'ingegneria delle energie rinnovabili e della simulazione di edifici per la progettazione solare passiva e attiva). Nel dettaglio, ogni edificio è stato modellato con Tipo 88, gli scambiatori di calore con Tipo 5, le FCU con Tipo 996 e gli impianti fotovoltaici con Tipo 194.

4.2 Creazione del modello

Per garantire prestazioni superiori rispetto a quelle di un controllo locale tradizionale, un controllo MPC, utilizzato a fini energetici, deve essere dotato di input di previsione affidabili e modelli accurati della domanda energetica. Per questi motivi il modello di previsione della domanda energetica dell'edificio preso in analisi è stato realizzato tramite una ANN, alla quale sono stati forniti come input i guadagni termici totali, ovvero la radiazione solare, le apparecchiature interne e l'illuminazione, insieme alla temperatura dell'ambiente misurata a bulbo secco e alla temperatura del termostato dell'utente. La selezione degli input più adeguati da immettere nella rete per l'affidabilità delle previsioni della domanda di energia richiesta potrebbe essere effettuata con la tecnica dell'analisi fattoriale. Questa tecnica statistica consente di spiegare la correlazione fra le molteplici variabili prese in considerazione in un numero ridotto di fattori. Tali fattori o anche detti "variabili latenti" (poiché sono impossibili da osservare in maniera diretta) sono ottenuti come combinazione lineare delle variabili prese in considerazione in origine, a meno di una piccolissima perdita di informazione. Il modello matematico di analisi fattoriale afferma che l'informazione contenuta in ogni variabile è composta da un'informazione condivisa e da un'informazione specifica [37]. Tale analisi, nel caso di studio preso in considerazione, è stata ritenuta superflua dato che la situazione e le variabili fisiche che influenzano la potenza refrigerante (output) si conoscono a priori. Gli input e i target presi in considerazione sono riferiti ai mesi di luglio ed agosto e sono stati esaminati con un intervallo temporale di un'ora.

Inizialmente è stata decisa la migliore architettura ANN che rappresentasse l'edificio del caso di studio da un punto di vista logico-matematico. La scelta è ricaduta nella tipologia di rete dinamica, nello specifico la NARX (*Non Linear Autoregressive network with exogenous inputs*) proprio per la sua capacità di analizzare gli input misurati in un intervallo temporale predefinito. La creazione della NARX e il successivo addestramento sono avvenuti nel software MATLAB. Tramite il tool dedicato "*ntstool*" la costruzione della rete è avvenuta in una interfaccia guidata che ha permesso di arrivare facilmente ad un primordiale script. I vari step del tool consistono dapprima nell'inserimento dei valori di input (guadagni, temperatura ambiente, temperatura esterna, temperatura del termostato dell'edificio) e di target (potenza refrigerante), rispettivamente in una matrice

1488 x 3 e 1488 x 1 (1488 rappresenta il numero totale di ore di luglio e agosto); il passo successivo prevede di definire le percentuali di divisione del set di dati in “*training*”, “*validation*” (utilizzati per misurare la generalizzazione della rete e per interrompere il processo quando la generalizzazione smette di migliorare) e “*testing*” (forniscono una misura indipendente delle prestazioni della rete durante e senza influenzarla). Di seguito vengono scelti i numeri di neuroni nascosti, i ritardi nell’architettura della rete e la tipologia di funzione di addestramento. Una volta terminati tutti questi passaggi è possibile estrapolare la rete NARX sotto forma di script, così da poterlo modificare e adattare al raggiungimento del nostro obiettivo.

4.2.1 Modifica dello script e addestramento della rete

Lo script della rete NARX scelta, generato dal tool precedentemente descritto, è una versione con impostazioni di default e deve essere adattato al caso di studio (*lo script modificato e consultabile nell’appendice 1*). La prima modifica apportata riguarda il criterio di divisione dei data set, passando dalla funzione di divisione “*dividerand*” (randomica) alla “*divideInd*” che permette di dare un ordine arbitrario e non randomico ai dati di input migliorando le prestazioni della rete nell’ottica di previsione futura. La divisione è avvenuta impostando il mese di luglio come *train* data, la prima metà di agosto come test data e la seconda metà di agosto come *validation* data. Oltre alla divisione, è importante prestare attenzione nel selezionare una dimensione appropriata del set di dati. Un set di dati troppo piccolo potrebbe portare a una scarsa interpolazione generale della rete. Troppi dati, d'altra parte, potrebbero comportare un eccesso di adattamento del problema. Il sovradimensionamento intensifica la capacità di interpolazione della rete, risultando in una scarsa rappresentazione dell'output quando vengono forniti nuovi dati alla rete. In questo caso specifico è stato considerato tutto il data set, ovvero 1488 dati orari perché ritenuto non eccessivamente grande.

Le successive modifiche sono avvenute per tentativi e sono state apportate per migliorare l’addestramento della rete portandola nella sua versione definitiva. Queste modifiche, che verranno analizzate più tardi, consistono nella scelta del numero di neuroni nascosti, dei ritardi e della funzione di addestramento più adeguata. Analizzando nel dettaglio il

processo di addestramento si nota come esso non avviene sfruttando la rete “*net*” che rappresenta lo script, bensì usando una sua variante generata dallo stesso e denominata “*nets*”. Essa è essenzialmente la rete creata tramite script in forma “*open loop*” (o ad anello aperto o in serie-parallelo), quindi ci garantisce una migliore previsione studiando i target forniti. Una volta addestrata tale rete, si passa alla forma in “*close-loop*” (o ad anello chiuso o in parallelo) per predire valori fornendo esclusivamente input esterni.

Il codice da lanciare per addestrare la rete è: `[nets, tr] = train (nets, xs, ts, xis, ais)`, dove `xs,ts,xis` e `ais` rappresentano i dati traslati di un certo ritardo per essere compatibili ed usufruibili dalla rete in open-loop. Tali dati vengono trasformati tramite la funzione “*preparents*” che si occupa di preparare i dati delle *time-series* in modo da tenere i dati storici al 100% invariati mentre fornisce alla rete *close-loop* e alla rete open-loop dati con i ritardi adeguati ad ognuna di esse. A questo punto si imposta un numero di iterazioni da far eseguire alla rete, e alla fine di tale processo si procede con il calcolo della performance. Sulla base del valore dell’ RMSE (Radice dell’errore quadratico medio) tra l’output della rete e i valori di target, insieme ai relativi grafici, si determina la necessità di fermare o continuare l’addestramento potendo reiterare di nuovo o cambiando il numero di neuroni e la funzione di addestramento.

La scelta del numero di neuroni, come la dimensione del data set, influenza la capacità di interpolazione della rete. Infatti, un numero elevato di neuroni e di strati di neuroni comporta ad un eccessivo adattamento (*over fitting*) della rete. Per questo motivo l’architettura del modello definitivo scelta per il modello in esame è composta da uno strato con 6 neuroni. Per quanto riguarda la funzione di addestramento, la scelta è ricaduta nella “*Levenberg-Marquardt*” (LM). Si tratta di funzione di retro-propagazione che utilizza derivate jacobiane, ed è in grado di gestire velocemente e con precisione pacchetti di dati non eccessivamente grandi, proprio come nel nostro caso.

4.2.2 Analisi delle prestazioni della rete

La rete definitiva sviluppata per la previsione della domanda energetica dell’edificio ha generato un valore di $RMSE = 1.8682$ kW con relativo plot in *Figura 2*.




Figura 12: Plot di confronto fra output e target (COOLING POWER) della rete neurale con 3 input e 1 output a 6 neuroni addestrata tramite LM

Il valore così elevato dell'RMSE potrebbe portare a pensare che la rete abbia delle basse prestazioni. Tuttavia, la causa di tale valore è dovuta dall'imprecisione della rete nel prevedere i "picchi di potenza". Ciò risulta essere del tutto normale perché sbalzi occasionali di potenza refrigerante richiesta dall'edificio (circa 12 kW) risultano comunque di difficile previsione, a prescindere dalle abilità della rete stessa. Infatti, la rete riesce a prevedere e simulare con precisione fino ad un tetto massimo di circa 8-9 kW, proprio perché le irregolarità sono più saltuarie e di difficile previsione, essendo prettamente randomiche. A conferma di quanto detto, nella Figura 3, viene graficato un




Figura 13: Plot di confronto output e target in un lasso temporale di 48 ore

periodo di tempo di 48 ore della fine del mese di luglio e risulta evidente l'accuratezza della previsione. Andando a calcolare l'RMSE relativo al breve periodo di tempo, si ottiene un valore di 0.3429 kW che risulta giustamente più basso rispetto al valore di RMSE globale di 1.8682 kW. Pertanto, si può concludere che la domanda di raffreddamento (Q_{zone}) stimata dalla NARX è sufficientemente accurata. Sono stati inoltre richiesti numerosi tentativi di prova ed errori prima di ottenere una ANN valida [29].

4.3 Il controllo

Poiché la NARX consente di prevedere la domanda di raffreddamento di una casa unifamiliare nel quartiere residenziale, è possibile progettare un MPC basato sulla NARX che sia in grado di sfruttare la previsione della domanda per ridurre al minimo il consumo di energia primaria dell'edificio. Più precisamente, nel presente studio l'MPC può ridurre al minimo l'elettricità assorbita dalla rete (E_{GRID}) dalla pompa di calore installata nell'edificio. Insieme alla richiesta di raffreddamento, che è una funzione della temperatura nominale interna ($Q_{ZONE} = Q_{ZONE}(T_{SP})$), l'MPC dovrebbe essere in grado di conoscere le fonti di energia gratuite disponibili nel sistema in un certo orizzonte di previsione, cioè l'energia termica fredda proveniente dal DCS (Q_{DC}) e l'elettricità prodotta dall'impianto fotovoltaico (E_{PV}), nonché il coefficiente di prestazione (COP) del AWHP a carico variabile utilizzato nell'edificio. Se tutte queste quantità sono note, l'MPC è in grado di elaborare un algoritmo di minimizzazione dell'energia e determinare una temperatura di setpoint interna ottimale (T_{SP}) in base alla disponibilità di flessibilità energetica dell'edificio. La variabile T_{SP} non può assumere qualsiasi valore, ma il suo dominio è limitato nell'insieme di vincoli $\{24.5, 25.5, 26.5, 27.5\}$ ° C, al fine di garantire un livello di comfort termico adeguato e poter usufruire della flessibilità dell'edificio. Dato che l'MPC gestisce il controllo locale, è stata utilizzata una risoluzione T_{SP} di 1 ° C per riprodurre il comportamento di un termostato tradizionale.

È necessario precisare che, data la natura del sistema multi-energia in fase di studio, l'obiettivo dell'MPC non è limitato al solo calcolo di una temperatura di setpoint ottimale. Infatti, a seconda della disponibilità delle fonti alternative di energia nell'orizzonte di previsione scelto, l'MPC dovrebbe fornire all'unità di controllo tre dati

per ogni fase temporale: una temperatura di setpoint interna ottimale (T_{SP}), un controllo booleano per il funzionamento dell'AWHP (CTRL_PHP) e un controllo booleano per lo scambio di calore con il DCS (CTRL_DC). Sulla base di quanto detto, non è possibile scrivere una funzione obiettivo fondata su un'equazione del bilancio energetico. Per il sistema multi-energia preso in esame, dove le fonti di energia gratuite dovrebbero essere utilizzate il più possibile secondo la flessibilità energetica fornita dall'edificio, è necessario suddividere il problema energetico per casi. Innanzitutto, si definiscono:

- n_1 la durata del problema da simulare e $i = \{1, 2, \dots, n_1\}$ il passo temporale della simulazione, con incrementi di 1 ora = time-step
- n_2 il numero dei T_{SP} che possono essere impostati con $j = \{1, \dots, n_2\}$ che in questo caso sono

$$\left\{ \begin{array}{l} \text{se } j = 1, T_{SP} = 24.5 \\ \text{se } j = 2, T_{SP} = 25.5 \\ \text{se } j = 3, T_{SP} = 26.5 \\ \text{se } j = 4, T_{SP} = 27.5 \end{array} \right.$$
- n_3 l'orizzonte temporale di previsione e $k = \{1, \dots, n_3\}$ l'indice che scorre l'orizzonte temporale di previsione per l'MPC, con incrementi di 1 ora = time-step

L'MPC dovrà valutare 3 casi e, come si noterà, il primo comporterà la risoluzione di un banale problema matematico, mentre negli altri due sarà richiesta la definizione di una funzione obiettivo di energia che dovrà essere minimizzata dall' algoritmo di ottimizzazione, ovvero l'energia elettrica prelevata dalla rete $E_{GRID}(T_{SP})$.

Caso 1. L'energia elettrica prodotta dal fotovoltaico è disponibile e soddisfa completamente l'energia elettrica assorbita dalla pompa di calore.

Se $E_{PV} \geq E_{HP}$ allora $E_{GRID} = 0$

$[CTRL_DC] = 0, [CTRL_PHP] = 1, T_{SP} = 24,5 \text{ } ^\circ\text{C}$

Caso 2. L'energia elettrica prodotta dal fotovoltaico non è sufficiente ad alimentare la pompa di calore e l'energia termica frigorifera disponibile dal DCS è maggiore di quella

richiesta dall'edificio. Il valore ottimale di T_{SP} viene scelto in base alla minimizzazione della funzione obbiettivo.

Se $E_{PV} < E_{HP}$ e $Q_{DC} \geq Q_{ZONE,k}(T_{SP,j})$ allora $\dot{P}_{GRID} = 0$

$$E_{GRID,k,j} = \begin{cases} E_{GRID,k,j} = \left(\frac{Q_{ZONE,k}(T_{SP,j}) - Q_{DC,k}}{COP_k} - E_{PV,k} \right) & \text{se } \left(\frac{Q_{ZONE,k}(T_{SP,j}) - Q_{DC,k}}{COP_k} - E_{PV,k} \right) \geq 0 \\ E_{GRID,k,j} = 0 & \text{se } \left(\frac{Q_{ZONE,k}(T_{SP,j}) - Q_{DC,k}}{COP_k} - E_{PV,k} \right) < 0 \end{cases}$$

$$\min \left[\sum_k^{n_3} \left(\frac{Q_{ZONE,k}(T_{SP,j}) - Q_{DC,k}}{COP_k} - E_{PV,k} \right) \right] \quad \text{con } j = \{1, \dots, 4\}$$

con il vincolo che: $\forall k \forall j, E_{GRID,k,j} \geq 0$

[CTRL_DC] = 1, [CTRL_PHP] = 0, T_{SP} dall'ottimizzazione

Caso 3. Entrambe le fonti di energia alternativa non sono sufficienti e il valore ottimale di T_{SP} viene scelto in base alla minimizzazione della funzione obbiettivo.

Se $E_{PV} < E_{HP}$ e $Q_{DC} < Q_{ZONE,k}(T_{SP,j})$ allora $\dot{P}_{GRID} > 0$

$$E_{GRID,k,j} = \begin{cases} E_{GRID,k,j} = \left(\frac{Q_{ZONE,k}(T_{SP,j}) - Q_{DC,k}}{COP_k} - E_{PV,k} \right) & \text{se } \left(\frac{Q_{ZONE,k}(T_{SP,j}) - Q_{DC,k}}{COP_k} - E_{PV,k} \right) \geq 0 \\ E_{GRID,k,j} = 0 & \text{se } \left(\frac{Q_{ZONE,k}(T_{SP,j}) - Q_{DC,k}}{COP_k} - E_{PV,k} \right) < 0 \end{cases}$$

$$\min \left[\sum_k^{n_3} \left(\frac{Q_{ZONE,k}(T_{SP,j}) - Q_{DC,k}}{COP_k} - E_{PV,k} \right) \right] \quad \text{con } k j = \{1, \dots, 4\}$$

con il vincolo che: $\forall k \forall j, E_{GRID,k,j} \geq 0$

[CTRL_DC] = 1, [CTRL_PHP] = 1, T_{SP} dall'ottimizzazione.

La funzione obiettivo che l'algoritmo di ottimizzazione MPC deve minimizzare si basa su un bilancio energetico generale dell'edificio, valutato per l'intero orizzonte di previsione scelto. Può essere scritto come:

$$E_{GRID,k} = \sum_k^{n_3} E_{GRID,k,j} \quad (1)$$

Dove per ogni k

$$E_{GRID,k,j} = \frac{Q_{ZONE,k}(T_{SP,j}) - Q_{DC,k}}{COP_k} - E_{PV,k} \quad \text{se } \frac{Q_{ZONE,k}(T_{SP,j}) - Q_{DC,k}}{COP_k} - E_{PV,k} \geq 0$$

$$E_{GRID,k,j} = 0 \quad \text{se } \frac{Q_{ZONE,k}(T_{SP,j}) - Q_{DC,k}}{COP_k} - E_{PV,k} < 0$$

Attraverso l'equazione (1), per ogni time step l'MPC può stimare l'energia elettrica complessiva che il sistema raccoglierà dalla rete fino alla fine dell'orizzonte di previsione. L'algoritmo di minimizzazione dell'MPC deve quindi trovare per quale T_{SP} l'elettricità complessiva assorbita dalla rete è minima insieme ai controlli booleani in base al caso specifico del problema.

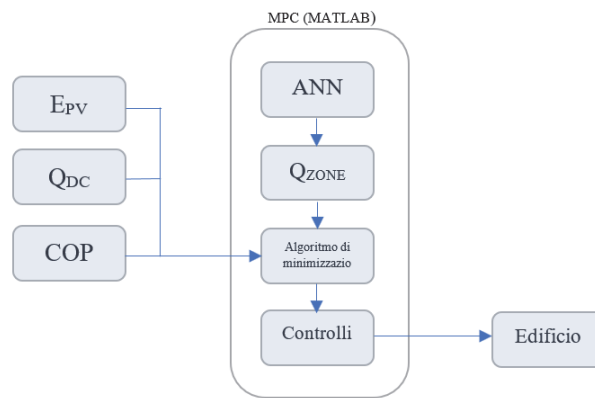


Figura 14: Schema a blocchi dell'Algoritmo di minimizzazione

La Figura 4 rappresenta uno schema a blocchi che riassume l'operazione MPC e la sua interazione con l'edificio. Nell'appendice 2 è possibile visionare l'algoritmo di ottimizzazione. Lo sviluppo di tale algoritmo è avvenuto in ambiente MATLAB così da consentirgli di interfacciarsi direttamente con la ANN rappresentativa del modello dell'edificio.

4.4 Analisi dei risultati

L'ottimizzazione è stata effettuata con un orizzonte temporale di previsione di 6 ore su tutto il pacchetto di dati che copre un periodo di 1488. Analizzando i risultati ottenuti, è stato notato come i segnali di controllo (CTRL_DC, CTRL_PHP) e T_{SP} sono molto simili per tutto il periodo di simulazione. Essi, infatti, hanno un andamento ciclico a meno di qualche piccola differenza che può essere attribuita al ritardo o all'anticipo di qualche ora della disponibilità di energia termica frigorifera proveniente dal DCS, o dalle condizioni climatiche particolarmente soleggiate dei due mesi estivi che hanno garantito al fotovoltaico un'ottima produzione di energia elettrica. In entrambi i mesi l'MPC dà la priorità all'uso di energia elettrica prodotta dall'impianto fotovoltaico, in quanto non immagazzinabile, per alimentare la pompa di calore a carico variabile. Se non è possibile soddisfare la richiesta di raffreddamento dell'edificio con le fonti di energia gratuite, l'MPC consente all'AWHP a carico variabile di raccogliere la frazione rimanente di energia dalla rete. Inoltre, l'MPC permette di sbloccare la flessibilità energetica dell'edificio grazie alla sua capacità di regolare la temperatura variabili interna del setpoint. Ciò consente di effettuare un preraffreddamento dell'edificio diverse ore prima della richiesta effettiva di raffreddamento. Per studiare in dettaglio il funzionamento dell'MPC è necessario analizzare la disponibilità delle fonti di energia gratuita insieme all'analisi della temperatura variabile interna del setpoint. Si prenda come riferimento il controllo dell'edificio in una giornata tipo attraverso un sistema che non utilizza un orizzonte temporale per ottimizzare il consumo di energia (Figura 15) e lo si confronti con l'MPC sviluppato nella stessa giornata (Figura 16). La Figura 15 mostra che in una giornata tipo, la temperatura nominale è fissata a $25,5^{\circ} C$. Anche senza MPC, il sistema è in grado di utilizzare le fonti di energia gratuite disponibili. Tuttavia, ciò è possibile solo quando esiste una corrispondenza temporale tra le fonti e la domanda di raffreddamento. Senza l'MPC, il controllo di riferimento non è in grado di operare un preraffreddamento dell'edificio, quindi ci sono periodi in cui l'assorbimento di energia elettrica dalla rete non può essere evitato (alle 17:00 e alle 18:00 nella Figura 15). In questa configurazione, il funzionamento del sistema multi-energia e l'interazione tra i suoi sottosistemi non sono ottimizzati, portando a uno sfruttamento inadeguato delle fonti di

energia alternative disponibili. La riduzione del consumo di energia primaria è quindi limitata, anche in presenza di un DCS e di un impianto fotovoltaico.

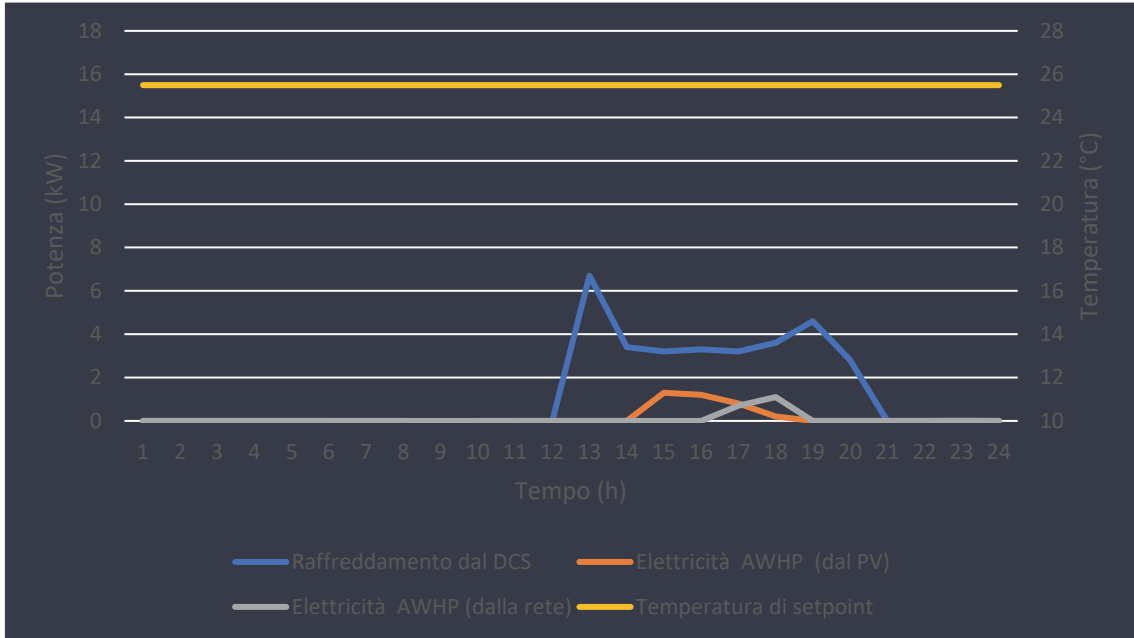


Figura 15: Controllo del caso di riferimento

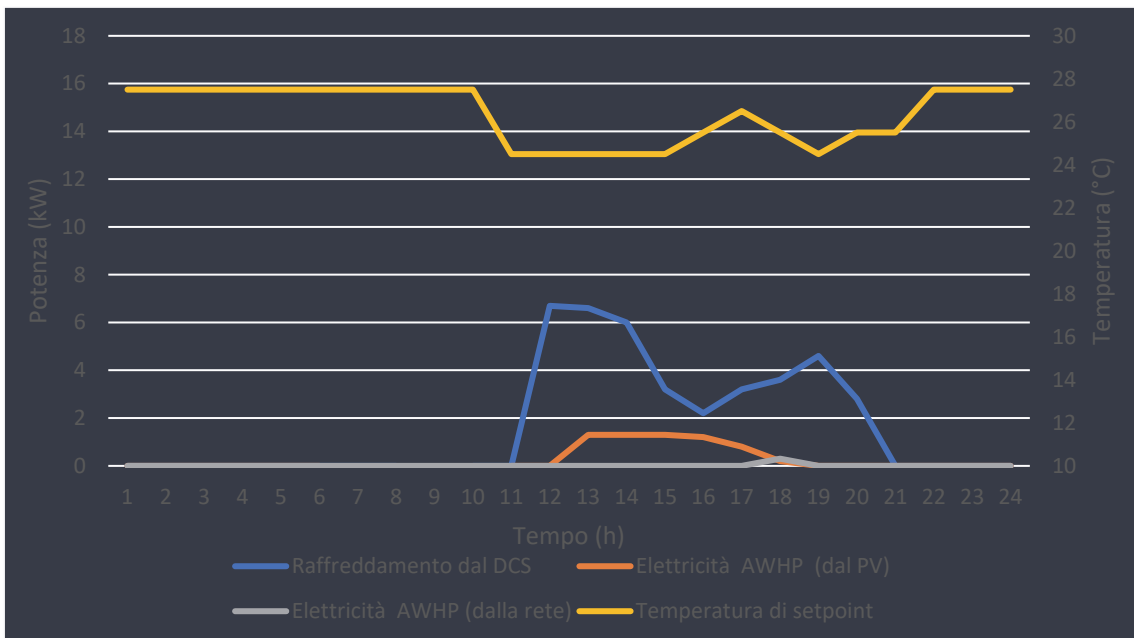


Figura 16: Controllo MPC

La Figura 16, invece, mostra come opera l'MPC con un orizzonte di previsione di 6 ore. Rispetto alla Figura 15, si può notare che la temperatura del setpoint può variare tra 24,5 e 27,5 ° C. Per ogni ora, la T_{SP} utilizzata nel controllo locale del termostato dell'edificio deriva dall'ottimizzazione energetica effettuata dall'MPC, che cerca di sbloccare la flessibilità energetica dell'edificio stesso. Prevedendo una richiesta di raffreddamento nelle ore più calde della giornata, l'MPC sfrutta la disponibilità di energia termica fredda proveniente dal DCS e l'energia prodotta dai moduli fotovoltaici già dalle ore precedenti in cui ci sarà tale richiesta, abbassando il T_{SP} per ottenere un preraffreddamento dell'edificio. Nello specifico, il preraffreddamento si è dimostrato particolarmente efficace dalle “ore 17 alle ore 18”, dove in mancanza di energia gratuita il prelievo dalla rete primaria si è ridotto precisamente dell'84% rispetto al caso di riferimento.

In generale i risultati ottenuti dall'algoritmo di ottimizzazione si sono dimostrati all'altezza delle aspettative riducendo l'elettricità complessiva assorbita dalla rete con un valore superiore al 60%. Con l'MPC, il sistema è in grado di evitare l'assorbimento di energia dalla rete elettrica, soprattutto nelle ore tarde del giorno, quando la disponibilità delle fonti di energia gratuite è limitata. Lo studio, al di là di qualche caso particolare, ha evidenziato che un sistema multienergia non è in grado di ridurre completamente il consumo di energia primaria perché non è possibile evitare discrepanze temporali tra le fonti e la domanda. Tuttavia, l'uso di un MPC basato sull'ANN può ridurre i disallineamenti sbloccando la flessibilità energetica dell'edificio e quindi portare al minimo l'utilizzo di energia primaria.

5 CAPITOLO 5 – CONCLUSIONI

Questo studio si è concentrato sulla creazione di un modello di controllo predittivo (MPC) di un edificio residenziale posto in contesto multienergetico al fine di ottimizzare l'energia primaria prelevata dalla rete. Sono state quindi dimostrate oltre le capacità di previsione delle reti neurali scelte come modello predittivo dell'MPC anche come tali previsioni, associate a diversi vettori energetici, possano essere elaborate dall'MPC stesso al fine di minimizzare l'energia elettrica prelevata dalla rete (EGRID) selezionando il controllo ottimale.

Superato lo scoglio dovuto alla selezione di input e target adeguati alla creazione della rete neurale, quest'ultima è risultata essere perfettamente in grado di processare il pacchetto dati e relazionarsi adeguatamente all'interno dell'MPC. I risultati di previsione si sono dimostrati, al netto di qualche imprecisione dovuta all'impossibilità di prevedere picchi improvvisi di domanda energetica, efficienti e affidabili. La rete, dunque, ha svolto alla perfezione il ruolo di modello predittivo seppur nelle condizioni complesse che possono derivare dall'analisi di un edificio collegato a molteplici fonti di energia di natura differente.

Una volta ottenute le previsioni, grazie all'equazione di ottimizzazione dell'energia si è riusciti ad ottenere un controllo ottimale sull'attivazione dei vettori energetici. Infatti, per ogni fase temporale dell'ambiente di simulazione, l'MPC cerca di minimizzare EGRID selezionando l'opzione ottimale di temperatura interna (T_{sp}), parametro di flessibilità del sistema. Tale ottimizzazione è risultata essere il centro nevralgico di tutto lo studio, grazie ad essa infatti si è riusciti ad abbattere in maniera sostanziale lo sfruttamento di risorse e diminuire drasticamente i consumi di energie primarie.

Nella sua complessità lo studio effettuato ha reso possibile elaborare e creare un controllo in base a delle predizioni per migliorare la flessibilità energetica di un edificio e ciò che ne consegue potrebbe aprire a risvolti futuri dove un sistema di controllo predittivo basato su una rete neurale possa essere applicato ad un intero distretto o persino in futuro, venendo riadattato e ampliato, ad una intera città. Ciò porterebbe oltre all'evidente riduzione di consumi in maniera esponenziale e al drastico crollo dell'impatto ambientale, anche ad una più semplice e rapida gestione del sistema energetico cittadino.

APPENDICE 1

```

1  clear all
2  clc
3
4  [trainInd,testInd,valInd] = divideind(1488,1:744,745:1488,1117:1488);
5
6
7
8  data = xlsread('20191218_ANN_data.xlsx',9);
9  INPUT = data(:,2:4);
10 TARGETS = data(:,5:6);
11 ZONETEMPERATURE = TARGETS(:,1);
12 COOLINGPOWER = TARGETS(:,2);
13
14 X = tonndata(INPUT,false,false);
15 T = tonndata(TARGETS,false,false);
16
17
18 trainFcn = 'trainbr';
19
20
21 inputDelays = 1;
22 feedbackDelays = 1;
23 hiddenLayerSize = 4;
24 net = narxnet(inputDelays,feedbackDelays,hiddenLayerSize,'open',trainFcn);
25
26 net.inputs{1}.processFcns = {'removeconstantrows','mapminmax'};
27 net.inputs{2}.processFcns = {'removeconstantrows','mapminmax'};
28
29 [x,xi,ai,t] = preparets(net,x,{},T);
30
31 net.divideFcn = 'divideind';
32 net.divideMode = 'time';
33 net.divideParam.trainInd = trainInd;
34 net.divideParam.valInd = valInd;
35 net.divideParam.testInd = testInd;
36
37
38 net.performFcn = 'mse';
39
40
41 net.plotFcns = {'plotperform','plottrainstate','ploterrhist',...
42               'plotregression','plotresponse','ploterrcorr','plotinerrcorr'};
43
44
45 [net,tr] = train(net,x,t,xi,ai);
46
47
48 y = net(x,xi,ai);
49 e = gsubtract(t,y);
50 performance = perform(net,t,y);

```

```

51
52
53 trainTargets = gmultiply(t,tr.trainMask);
54 valTargets = gmultiply(t,tr.valMask);
55 testTargets = gmultiply(t,tr.testMask);
56 trainPerformance = perform(net,trainTargets,y);
57 valPerformance = perform(net,valTargets,y);
58 testPerformance = perform(net,testTargets,y);
59
60
61 netc = closeloop(net);
62 netc.name = [net.name ' - Closed Loop'];
63
64 [xc,xic,aic,tc] = preparets(netc,X,{},T);
65 yc = netc(xc,xic,aic);
66 closedLoopPerformance = perform(net,tc,yc);
67
68
69 numTimesteps = size(x,2);
70 knownOutputTimesteps = 1:(numTimesteps-5);
71 predictOutputTimesteps = (numTimesteps-4):numTimesteps;
72 x1 = X(:,knownOutputTimesteps);
73 T1 = T(:,knownOutputTimesteps);
74 [x1,xio,aio] = preparets(net,x1,{},T1);
75 [y1,xfo,afo] = net(x1,xio,aio);
76
77 x2 = X(1,predictOutputTimesteps);
78 [netc,xic,aic] = closeloop(net,xfo,afo);
79 [y2,xfc,afc] = netc(x2,xic,aic);
80 multiStepPerformance = perform(net,T(1,predictOutputTimesteps),y2);
81
82 nets = removedelay(net);
83 nets.name = [net.name ' - Predict One Step Ahead'];
84
85 [xs,xis,ais,ts] = preparets(nets,X,{},T);
86 ys = nets(xs,xis,ais);
87 stepAheadPerformance = perform(nets,ts,ys);
88
89
90 if (false)
91     genFunction(net,'myNeuralNetworkFunction');
92     y = myNeuralNetworkFunction(x,xi,ai);
93 end
94 if (false)
95     genFunction(net,'myNeuralNetworkFunction','MatrixOnly','yes');
96     x1 = cell2mat(x(1,:));
97     x2 = cell2mat(x(2,:));
98     xi1 = cell2mat(xi(1,:));
99     xi2 = cell2mat(xi(2,:));
100     y = myNeuralNetworkFunction(x1,x2,xi1,xi2);
101 end
102
103

```

```
104 if (false)
105
106     gensim(net);
107 end
108
109
110 Z=tonndata(INPUT,false,false);
111 netc(Z);
112 L= length(ans);
113
114 for i = 1:L
115     tempoutput(i,1)=ans{i}(1);
116 end
117
118 for i = 1:L
119     coolingoutput(i,2)=ans{i}(2);
120 end
121 coolingoutput(:,1) = [ ] ;
122
123 coolingoutput(coolingoutput <= 0)=0 ;
124
125 tempo=(1:1489);
126 RMSE_zone_temperature = sqrt(mean((tempoutput-ZONETEMPERATURE).^2))
127 RMSE_cooling_power = sqrt(mean((coolingoutput-COOLINGPOWER).^2))
128
129
130 subplot(1,2,1);
131 plot(tempo,ZONETEMPERATURE, 'red', tempo, tempoutput, 'blue');
132 subplot(1,2,2);
133 plot(tempo,COOLINGPOWER, 'red', tempo, coolingoutput, 'blue');
```

[Published with MATLAB® R2019a](#)

APPENDICE 2

```

134 n1= 50;%numero di timestep
135 n2= 4;%numero di Tset (se si modifica il numero va modificata anche la riga 31)
136 n3= 6;%numero di ore di previsione
137
138
139 %- comando apri file excel --->
140 INPUTload = xlsread('INPUT.xlsx')
141
142 %- comando apri netc --->
143 load('netc.mat')
144
145     tsolar=INPUTload(1:n1,2);
146     guadagni=INPUTload(1:n1,3);
147     COPi=INPUTload(1:n1,4);
148     Ppvi=INPUTload(1:n1,5);
149     Epvi=Ppvi;
150     Qdci=INPUTload(1:n1,6);
151
152
153
154
155     for i= [1: n1-n3]
156
157         for j=[1:n2]
158
159
160
161             for k=[i:i-1+n3]
162
163
164                 tset=[24.5;25.5;26.5;27.5];
165                 tset(j);
166
167                 for q=1:n1
168                     tset(q)=ans;
169                 end
170
171             INPUT=[tset,tsolar,guadagni];
172
173
174             %- comando mettere input 3 input in una cella--->
175             x = tonndata(INPUT,false,false);
176             %- comando utilizzare netc per predire output --->
177             netc(x);
178             %- scorporre output predetti --->
179             L= length(ans);
180
181             for f = 1:L
182                 QzoneiTset(f,2)=ans{f}(2);
183             end

```

```

184     QzoneiTset(:,1) = [ ];
185
186     QzoneiTset(QzoneiTset <= 0)=0;
187     Pphi=QzoneiTset./COPi;
188
189
190     end
191     end
192
193     if (Ppvi(k) >= Pphi(k));
194         Egrid(k)=0;
195     end
196     if (Ppvi(k) < Pphi(k));
197         if (Qdci(k) >= QzoneiTset(k));
198
199             Egrid(k)=[((QzoneiTset(k)-Qdci(k))./COPi(k))-Epvi(k)]';
200             if Egrid(k)>=0;
201                 Egrid(k)=Egrid(k);
202             else Egrid(k)<0;
203                 Egrid(k)=0;
204
205             end
206
207
208         else (Qdci(k) < QzoneiTset(k));
209
210             Egrid(k)=[((QzoneiTset(k)-Qdci(k))./COPi(k))-Epvi(k)]';
211
212             if Egrid(k)>=0 ;
213                 Egrid(k)=Egrid(k);
214             else Egrid(k)<0;
215                 Egrid(k)=0;
216
217             end
218
219         end
220
221     end
222
223     [EgridTset(j)]=[sum(Egrid)];
224     Tsetottimale(i)=find(EgridTset==min(EgridTset),1);
225     EgridTsetmin(i)=[min(EgridTset)];
226     end
227
228
229
230
231
232     Tsetottimale=Tsetottimale';
233     EgridTsetmin=EgridTsetmin';
234
235     % per tset=[24.5;25.5;26.5;27.5]
236

```



```

237 Tsetottimale(Tsetottimale==1)=24.5;
238 Tsetottimale(Tsetottimale==2)=25.5;
239 Tsetottimale(Tsetottimale==3)=26.5;
240 Tsetottimale(Tsetottimale==4)=27.5;
241
242
243 %CONTROLLI
244
245 for z=1:n1-n3
246     ore=(1:n1-n3)'
247     Tsolarcontrolli=INPUTload(1:n1-n3,2);
248     guadagnicontrolli=INPUTload(1:n1-n3,3);
249     COPicontrolli=INPUTload(1:n1-n3,4);
250     INPUTCONTROLLI=[Tsetottimale,Tsolarcontrolli,guadagnicontrolli];
251     Y=tonndata(INPUTCONTROLLI,false,false);
252     netc(Y);
253
254     B= length(ans);
255
256     for m = 1:B
257         QzoneiTsetcontrolli(m,2)=ans{m}(2);
258     end
259     QzoneiTsetcontrolli(:,1) = [ ];
260     QzoneiTsetcontrolli(QzoneiTsetcontrolli <= 0)=0;
261     Phpicontrolli=QzoneiTsetcontrolli./COPicontrolli;
262
263     if Ppvi(z) >= Phpicontrolli(z)
264         CTRL_PHP(z)=1;
265         CTRL_DC(z)=0;
266     end
267     if (Ppvi(z) < Phpicontrolli(z))
268     if Qdci(z) >= QzoneiTsetcontrolli(z)
269         CTRL_PHP(z)=0;
270         CTRL_DC(z)=1;
271     else Qdci(z) < QzoneiTsetcontrolli(z)
272         CTRL_PHP(z)=1;
273         CTRL_DC(z)=1;
274     end
275     end
276     CONTROLLI=[CTRL_PHP;CTRL_DC]';
277
278     end
279     end
280     CTRL_DC=CTRL_DC'
281     CTRL_PHP=CTRL_PHP'
282     %creare excel con risultati --->
283     %C:\Users\output.xlsx'
284     filename='risultati.xlsx';
285
286     %- incollare output in excel -->%file (colonna con ore, Emin,Tset min;controllo
287     dc,controlloph)
288     RISULTATI=[ore,EgridTsetmin,Tsetottimale,CTRL_DC,CTRL_PHP];

```

BIBLIOGRAFIA

- [1] AICARR HOURNAL NR. 8/2011, consultabile al sito https://issuu.com/aicarr/docs/2011_08_aj_aicarrjournal
- [2] Clauß J, Stinner S, Sartori I, Georges L. Predictive rule-based control to activate the energy flexibility of Norwegian residential buildings: Case of an air-source heat pump and direct electric heating. *Appl Energy* 2019;237:500–18.
- [3] Jensen SØ, Marszal-Pomianowska A, Lollini R, Pasut W, Knotzer A, Engelmann P, et al. IEA EBC annex 67 energy flexible buildings. *Energy Build* 2017;155:25–34.
- [4] Fischer D, Madani H. On heat pumps in smart grids: A review. *Renew Sustain Energy Rev* 2017; 70:342–57.
- [5] Bishop CM. Neural networks and their applications. *Rev Sci Instrum* 1994; 65:1803–32.
- [6] Arteconi A, Polonara F. Demand side management in refrigeration applications. *Int J Heat Technol* 2017;35: S58--S63
- [7] Sven Werner. International review of district heating and cooling, *Energy* vol.37, 2017; 622-24
- [8] Fischer David, Rautenberg Friederike, Wirtz Thomas, Wille-Haussmann Bernhard, Madani Hatef. Smart meter enabled control for variable speed heat pumps to increase PV self- consumption. In: Proceedings of the 24th IIR international congress of refrigeration; 2015. p. ID:580
- [9] Amin Mirakhorli, Bing Dong, Occupancy behavior based model predictive control for buildingindoor climate – A critical review. 2016; 499-513
- [10] Frauke Oldewurtel, Alessandra Parisio , Colin N. Jones , Dimitrios Gyalistras , Markus Gwerder , Vanessa Stauche, Beat Lehmannf , Manfred Morari. Use of model predictive control and weather forecasts for energy efficient building climate control, *Energy and Buildings* 45, 2012, 15-27
- [11] Xi X-C, Poo A-N, Chou S-K. Support vector regression model predictive control on a HVAC plant. *Control Eng Pract* 2007;15:897e908.

- [12] Karlsson H, Hagentoft C-E. Application of model based predictive control for water-based floor heating in low energy residential buildings. *Build Environ* 2011;46:556e69
- [13] Candanedo JA, Athienitis AK. Predictive control of radiant floor heating and solar-source heat pump operation in a solar house. *HVAC R Res* 2011;17: 235e56.
- [14] Giacomo Pietro Ferrari, APPLICAZIONE DI SCHEMI INNOVATIVI DI CONTROLLO PREDITTIVO ALLA SEZIONE DI REFRIGERAZIONE DI UN IMPIANTO PER IL TRATTAMENTO DEL GAS NATURALE, 2013-2014, 60-65, Politecnico di Milano
- [15] Zhu, D., Kim, J. Hu, and Zhu, D. Kim, J. Hu, A distributed approach to efficient model predictive control of building HVAC systems. *Proceeding of 2012 International High Performance Building Conference*. 2012
- [16] P.-D. Moros, an, R. Bourdais, D. Dumur, J. Buisson, A distributed MPC strategy based on Benders' decomposition applied to multi-source multi-zone temperature regulation, *J. Process Control* 21 (2011) 729–737.
- [17] Luca Giulioni, STOCHASTIC MODEL PREDICTIVE CONTROL WITH APPLICATION TO DISTRIBUTED CONTROL SYSTEMS, 2015, Politecnico di Milano
- [18] Valentina Rogora, Luca Rovellini, CONTROLLO PREDITTIVO PER L'INSEGUIMENTO DI TRAIETTORIA DI UN ALL TERRAIN VEHICLE, 2014, Politecnico di Milano
- [19] Abdul Afram*, Farrokh Janabi-Sharifi, Theory and applications of HVAC control systems - A review of model predictive control (MPC). *Building and Environment* 72 (2014) 343e355
- [20] X. Xu, S. Wang, Z. Sun, F. Xiao, A model-based optimal ventilation control strategy of multi-zone VAV air-conditioning systems, *Appl. Therm. Eng.* 29(2009) 91–104.

- [21] Široký J, Oldewurtel F, Cigler J, Prívvara S. Experimental analysis of model predictive control for an energy efficient building heating system. *Appl Energy* 2011;88(9):3079–87.
- [22] Reynolds J, Rezgui Y, Kwan A, Piriou S. A zone-level, building energy optimization combining an artificial neural network, a genetic algorithm, and model predictive control. *Energy* 2018;151:729–39
- [23] Afram A, Janabi-Sharifi F. Supervisory model predictive controller (MPC) for residential HVAC systems: Implementation and experimentation on archetype sustainable house in Toronto. *Energy Build* 2017;154:268–82.
- [24] Afram A, Janabi-Sharifi F, Fung AS, Raahemifar K. Artificial neural network (ANN) based model predictive control (MPC) and optimization of HVAC systems: A state of the art review and case study of a residential HVAC system. *Energy Build* 2017;141:96–113.
- [25] Ławryńczuk M, Ocloń P. Model Predictive Control and energy optimisation in residential building with electric underfloor heating system. *Energy* 2019;182:1028–44.
- [26] Cox SJ, Kim D, Cho H, Mago P. Real time optimal control of district cooling system with thermal energy storage using neural networks. *Appl Energy* 2019;238:466–80.
- [27] Articolo scientifico:” Reti neurali: cosa sono e a cosa servono”, disponibile all’indirizzo: https://www.ai4business.it/intelligenza-artificiale/deep-learning/reti-neurali/#I_modelli_di_apprendimento_delle_reti_neurali
- [29] Luca Carboni, RETI NEURALI: MODELLI ED ASPETTI APPLICATIVI IN SISTEMI DI CONTROLLO PREDITTIVI PER IMPIANTI MULTIENERGETICI, 2020
- [30] Corrado V, Ballarini I, Corgnati SP. Typology Approach for Building Stock: D6.2 National scientific report on the TABULA activities in Italy. 2012.
- [31] ISO UnE. Energy performance of buildings Calculation of energy use for space heating and cooling 2008:1–24.

- [32] American Society of Heating R and A-C, (ASHRAE) E. ASHRAE HANDBOOK FUNDAMENTALS. 1791 Tullie Circle, N.E., Atlanta, GA 30329: 2005
- [33] Viessmann. VITOCAL 200-S AWB/AWB-AC 201.B04/ .B07/ .B10 / .B13 /.B16. Commercial datasheet catalogue. 2017.
- [34] GmbH HQC. Q.PRO-G3 250-265. Photovoltaic module in polycrystalline silicon. Commercial datasheet catalogue 2013
- [35] “Wikipedia.it”, disponibile all’indirizzo:
https://it.wikipedia.org/wiki/Rete_neurale
- [36] Rota Bulò Samuel, Appunti di rete neurale, disponibile all’indirizzo
<https://www.dsi.unive.it/~srotabul/files/AppuntiRetiNeurali.pdf>
- [37] Wikipedia, disponibile all’indirizzo:
[https://it.wikipedia.org/wiki/Analisi_fattoriale#:~:text=In%20statistica%20e%20in%20psicometria,direttamente%20osservabili%20\(talvolta%20definite%20anche](https://it.wikipedia.org/wiki/Analisi_fattoriale#:~:text=In%20statistica%20e%20in%20psicometria,direttamente%20osservabili%20(talvolta%20definite%20anche)