

POLITECNICO DI TORINO

Laurea Magistrale in Ingegneria Gestionale



Tesi di Laurea Magistrale

Modelli ibridi per la predizione della temperatura indoor: case study Energy Center

Relatori

Prof. Davide PAPURELLO

Prof. Lorenzo BOTTACCIOLI

Prof. Andrea LANZINI

Candidata

Silvia DI GIÀ

8 Aprile 2021

Sommario

Negli stati dell'Unione Europea, il settore immobiliare è responsabile di una significativa percentuale del consumo energetico totale, in media il 40 per cento. La necessità impellente di intraprendere azioni concrete con il fine di identificare soluzioni per un utilizzo efficiente dell'energia negli edifici, sia sulla base di considerazioni ambientali sia politiche, è stata più volte ribadita anche in sede di Parlamento Europeo. Modelli predittivi di tipo white-box, grey-box e black-box trovano applicazione nel prevedere l'andamento della temperatura indoor, così da pianificare in modo ottimale il consumo legato al suo mantenimento. In questo studio, viene illustrato il potenziale dell'utilizzo di un modello di rete neurale LSTM con il fine di predire la temperatura all'interno di 15 uffici disposti sui tre piani dell'edificio Energy Center, collocato a Torino, in riferimento a diversi orizzonti di tempo (2 ore, 5 ore e 24 ore). Le performance predittive sono valutate in funzione dei criteri Root Mean Squared Error e Mean Absolute Error rispetto ai valori effettivi. Vengono inoltre illustrati i risultati dei test effettuati durante la calibrazione dei diversi parametri caratterizzanti, nell'ottica di identificare la struttura ottimale del modello. Il risultato dimostra che i modelli individuati sono in grado di fornire previsioni accurate per tutti gli orizzonti di tempo proposti, e potrebbero tutti potenzialmente essere utilizzati con il fine di operare un controllo di tipo predittivo e ottimizzare la domanda energetica.

Ringraziamenti

Un sentito grazie a tutte le persone che mi hanno permesso di concludere il mio percorso universitario e portare a termine questo lavoro di tesi.

Ringrazio tutti i relatori, in particolare prof. Davide Papurello e prof. Lorenzo Bottaccioli, per l'ottima guida e il supporto costante durante questi mesi di stesura della tesi, oltre che per i preziosi consigli e il tempo che sono riusciti a dedicarmi per indirizzare al meglio il mio lavoro.

Ringrazio, inoltre, la mia famiglia per la fiducia che ha continuato a riporre in me anche nei momenti di sconforto e demotivazione.

Per finire, ringrazio tutti gli amici, in particolare un ringraziamento speciale va a Nadia ed Emanuela, con cui ho avuto la fortuna di condividere tantissime avventure (e disavventure) universitarie e di superare insieme sia tanti traguardi sia momenti difficili, e a Sav, Z, Valentina e Roberto, che con i loro consigli e con una semplice parola di incoraggiamento sono riusciti a fare la differenza.

Indice

Elenco delle tabelle	VII
Elenco delle figure	IX
Glossario	XVIII
1 L'intelligenza artificiale per l'efficientamento energetico	1
1.1 Le sfide dell'efficientamento energetico	1
1.2 Principali benefici dell'applicazione di strategie di Model Predictive Control al settore	6
1.2.1 AI per il raffreddamento dei data center: il caso Google	13
2 Stato dell'arte	15
2.1 Software di simulazione energetica	15
2.1.1 Utilizzo	16
2.1.2 I principali software di simulazione energetica	20
2.1.3 Conclusioni	22
2.2 Modelli	26
2.2.1 Modelli Grey Box	32
2.2.2 Modelli Black-Box	55
3 Data preprocessing	73
3.1 Scope	73
3.2 Data integration e data cleaning	75
3.3 Feature selection	76
3.4 Feature creation	79
3.5 Data exploration	79
4 Implementazione dei modelli	85
4.1 Approccio	85
4.2 Definizione del modello	87

4.2.1	Architettura del modello	87
4.2.2	Training del modello	88
4.3	Test e risultati	90
4.3.1	Suddivisione in training, test e validation set	90
4.3.2	Metriche di performance	91
4.3.3	Approccio MISO	91
4.3.4	Approccio MIMO	102
5	Lavori futuri	191
6	Conclusioni	192
	Bibliografia	195

Elenco delle tabelle

2.1	Confronto tra i principali software in termini di tipologia di soluzione [Fonte Joana Sousa, Energy Simulation Software for Buildings: Review and Comparison][8]	22
2.2	Confronto tra i principali software in termini di durata dei tempi di calcolo [Fonte Joana Sousa, Energy Simulation Software for Buildings: Review and Comparison][8]	23
2.3	Confronto tra i principali software in termini di tipologia di soluzione in termini di completezza nei sistemi di energia rinnovabile [Fonte Joana Sousa, Energy Simulation Software for Buildings: Review and Comparison][8]	23
2.4	Confronto tra i principali software in termini di completezza nei sistemi elettrici ed equipment [Fonte Joana Sousa, Energy Simulation Software for Buildings: Review and Comparison][8]	24
2.5	Confronto tra i principali software in termini di completezza nei sistemi HVAC [Fonte Joana Sousa, Energy Simulation Software for Buildings: Review and Comparison][8]	24
2.6	Confronto tra i principali software in termini di completezza della descrizione geometrica [Fonte Joana Sousa, Energy Simulation Software for Buildings: Review and Comparison][8]	25
2.7	Vantaggi e svantaggi dei modelli white box	29
2.8	Vantaggi e svantaggi dei modelli grey box	30
2.9	Vantaggi e svantaggi dei modelli black box	31
3.1	Tabella riepilogativa degli intervalli ritenuti accettabili per alcune feature, tradottisi nei filtri applicati per l'esclusione di eventuali dati rumorosi nella fase di datapreprocessing	76
3.2	Riepilogo delle feature mantenute in seguito all'operazione di feature selection. (*) In totale il dataset include 5 temperature di setpoint e 5 temperature ambiente per ogni piano, relative per ogni piano a tutti gli uffici della manica corta, codificati come R-38, R-39, R-40, R-42, R-45.	78

4.1	Riepilogo del ruolo delle variabili per gli approcci MISO e MIMO . . .	86
4.2	Riepilogo della suddivisione in training, test e validation set in termini di quota sul totale e intervallo temporale	90
4.3	Tabella riepilogativa dei risultati ottenuti - Approccio MISO	102
4.4	Tabella riepilogativa dei risultati ottenuti - RMSE - Primo Piano - Approccio MIMO	188
4.5	Tabella riepilogativa dei risultati ottenuti - MAE - Primo Piano - Approccio MIMO	188
4.6	Tabella riepilogativa dei risultati ottenuti - RMSE - Secondo Piano - Approccio MIMO	189
4.7	Tabella riepilogativa dei risultati ottenuti - MAE - Secondo Piano - Approccio MIMO	189
4.8	Tabella riepilogativa dei risultati ottenuti - RMSE - Terzo Piano - Approccio MIMO	189
4.9	Tabella riepilogativa dei risultati ottenuti - MAE - Terzo Piano - Approccio MIMO	190
6.1	Tabella di confronto dei risultati con alcuni riferimenti - Approccio MIMO [33] . Tutti i risultati mostrati sono frutto di approssimazioni	194

Elenco delle figure

1.1	Consumi energetici del settore immobiliare rispetto al totale in UE [Fonte Eurostat]	2
1.2	Quote di consumo di energia per settore a livello globale [Fonte IEA]	3
1.3	Tasso di dipendenza energetica per i paesi UE dal 2000 al 2018 [Fonte Eurostat]	4
1.4	Quota di energia rinnovabile nel consumo finale lordo di energia per gli stati membri dell'Unione Europea dal 2010 al 2018 [Fonte Eurostat]	5
1.5	Albero del problema che riassume le sfaccettature delle criticità che si intende alleviare	6
1.6	Albero della soluzione che riassume gli effetti derivanti da un utilizzo dei modelli AI-based in campo edilizio]	12
1.7	Andamento dell'indicatore PUE in funzione del tempo durante il testing dell'efficacia del modello avvenuto in un data center reale [Fonte deepmind.com][7]	14
2.1	Interfaccia per l'inserimento delle coordinate nel software Energy Plus [Fonte Joana Sousa, Energy Simulation Software for Buildings: Review and Comparison][8]	16
2.2	Interfaccia di selezione dei materiali utilizzati e delle loro proprietà nel software Energy Plus [Fonte Joana Sousa, Energy Simulation Software for Buildings: Review and Comparison][8]	17
2.3	Interfaccia di aggiunta delle varie tipologie di day-schedule all'interno del software Energy Plus [Fonte Joana Sousa, Energy Simulation Software for Buildings: Review and Comparison][8]	18
2.4	Interfaccia di aggiunta delle informazioni sui termostati per il software Energy Plus [Fonte Joana Sousa, Energy Simulation Software for Buildings: Review and Comparison][8]	19
2.5	Rappresentazione del circuito termico nel modello ISO 13790	35
2.6	Rappresentazione del circuito termico nel modello VDI 6007-1	37
2.7	Rappresentazione dei circuiti termici equivalenti, con complessità 1R2C, 3R2C e 3R4C, secondo il modello di Fraisse	39

2.8	Rappresentazione del circuito equivalente per il modello basato sull'algoritmo genetico	42
2.9	Rappresentazione del circuito equivalente per l'm-esimo elemento per il modello DETECT [15]	45
2.10	Rappresentazione parziale del circuito equivalente nel modello di Braun et Al. [16]	48
2.11	Rappresentazione del circuito equivalente globale nel modello di Braun et Al. [16]	49
2.12	Comparazione fra reti neurali residuali e ODE: le prime definiscono una sequenza discreta di trasformazioni finite, le seconde, invece, passano dal discreto al continuo [17]	51
2.13	Rappresentazione del metodo adjoint sensitivity [17]	52
2.14	Rappresentazione del primo edificio con relativo circuito equivalente [19]	54
2.15	Rappresentazione del secondo edificio con relativo circuito equivalente [19]	54
3.1	Planimetria dell'edificio di riferimento: dall'alto in basso, primo, secondo e terzo piano. La zona di riferimento è inclusa all'interno del rettangolo rosso	74
3.2	Rappresentazione dell'intervallo temporale di estensione del dataset al termine delle integrazioni a partire dalle varie fonti	75
3.3	Matrice di correlazione fra le feature presenti originalmente; la correlazione aumenta raggiungendo il valore massimo in associazione al colore più scuro	77
3.4	Schematizzazione delle varie fasi di data preprocessing, con l'indicazione dell'effetto sulla dimensione e sulla numerosità del dataset	80
3.5	Andamento delle temperature ambiente del primo piano in funzione del tempo	80
3.6	Andamento delle temperature ambiente del secondo piano in funzione del tempo	81
3.7	Andamento delle temperature ambiente del terzo piano in funzione del tempo	81
3.8	Andamento del grado di umidità di mandata e di ritorno UTA in funzione del tempo	82
3.9	Andamento delle temperature di mandata e di ritorno dei collettori e della temperatura di mandata finale del pannello in funzione del tempo	82
3.10	Andamento delle temperature di immissione e ritorno UTA in funzione del tempo	83

4.1	Errore in funzione della complessità del modello (numero di layer) - I piano - Approccio MISO	93
4.2	Errore in funzione della complessità del modello (numero di layer) - II piano - Approccio MISO	94
4.3	Errore in funzione della complessità del modello (numero di layer) - III piano - Approccio MISO	94
4.4	Errore al variare della probabilità di dropout - I piano - Approccio MISO	95
4.5	Errore al variare della probabilità di dropout - II piano - Approccio MISO	96
4.6	Errore al variare della probabilità di dropout - III piano - Approccio MISO	96
4.7	Loss curve al crescere del learning rate; da sinistra a destra: 0.000001, 0.00001, 0.0001, 0.001 - Approccio MISO	98
4.8	Errore in funzione dell'ampiezza dell'orizzonte di predizione - I piano - Approccio MISO	100
4.9	Errore in funzione dell'ampiezza dell'orizzonte di predizione - II piano - Approccio MISO	100
4.10	Errore in funzione dell'ampiezza dell'orizzonte di predizione - III piano - Approccio MISO	101
4.11	Errore medio in funzione della numero di layer - I piano - Approccio MIMO	104
4.12	Errore medio in funzione della numero di layer - II piano - Approccio MIMO	104
4.13	Errore medio in funzione della numero di layer - III piano - Approccio MIMO	105
4.14	Errore massimo in funzione della numero di layer - I piano - Approccio MIMO	105
4.15	Errore massimo in funzione della numero di layer - II piano - Approccio MIMO	106
4.16	Errore massimo in funzione della numero di layer - III piano - Approccio MIMO	106
4.17	Tempo computazionale necessario per il training sui dati del I piano per 100 epoche e con un orizzonte di predizione di 5 ore in funzione della numero di layer - Approccio MIMO	107
4.18	Errore medio in funzione della probabilità di dropout - I piano - Approccio MIMO	108
4.19	Errore medio in funzione della probabilità di dropout - II piano - Approccio MIMO	108
4.20	Errore medio in funzione della probabilità di dropout - III piano - Approccio MIMO	109

4.21	Errore medio per tutti e tre i piani in funzione della struttura del modello - Tradizionale o Bidirezionale - Approccio MIMO	110
4.22	Errore massimo per tutti e tre i piani in funzione della struttura del modello - Tradizionale o Bidirezionale - Approccio MIMO	111
4.23	Tempo computazionale necessario per il training sui dati del I piano su 100 epoche in funzione della struttura del modello - Tradizionale o Bidirezionale - Approccio MIMO	111
4.24	Errore medio su tutti e tre i piani in funzione della struttura del modello - Tradizionale o Bidirezionale - per ciascun orizzonte di tempo - Approccio MIMO	112
4.25	Media su tutti e tre i piani dell'errore massimo in funzione della struttura del modello - Tradizionale o Bidirezionale - per ciascun orizzonte di tempo - Approccio MIMO	113
4.26	Errore medio in funzione della funzione di loss per un intervallo di predizione di 5 ore e tutti e tre i piani - Approccio MIMO	114
4.27	Errore massimo in funzione della funzione di loss per un intervallo di predizione di 5 ore e tutti e tre i piani - Approccio MIMO	115
4.28	Errore medio in funzione di ciascun ottimizzatore per un intervallo di predizione di 2 ore e tutti e tre i piani - Approccio MIMO	116
4.29	Errore medio in funzione di ciascun ottimizzatore per un intervallo di predizione di 5 ore e tutti e tre i piani - Approccio MIMO	117
4.30	Errore medio in funzione di ciascun ottimizzatore per un intervallo di predizione di 24 ore e tutti e tre i piani - Approccio MIMO	117
4.31	Errore medio sui tre piani per ciascun ottimizzatore in funzione dell'intervallo di predizione - Approccio MIMO	118
4.32	Errore medio (RMSE) di tutti e tre i piani ottenuto con l'ottimizzatore e la funzione di loss selezionata per ciascun orizzonte di predizione - Approccio MIMO	119
4.33	Errore medio (MAE) di tutti e tre i piani ottenuto con l'ottimizzatore e la funzione di loss determinata per ciascun orizzonte di predizione - Approccio MIMO	120
4.34	Errore medio (RMSE e MAE) calcolati su tutti e tre i piani con l'ottimizzatore e la funzione di loss determinata per ciascun orizzonte di predizione - Approccio MIMO	121
4.35	Distribuzione dell'errore medio RMSE ottenuto con funzione di loss e ottimizzatore selezionati in funzione dell'orizzonte di predizione - I piano - Approccio MIMO	122
4.36	Distribuzione dell'errore medio RMSE ottenuto con funzione di loss e ottimizzatore selezionati in funzione dell'orizzonte di predizione - II piano - Approccio MIMO	122

4.37	Distribuzione dell'errore medio RMSE ottenuto con funzione di loss e ottimizzatore selezionati in funzione dell'orizzonte di predizione - III piano - Approccio MIMO	123
4.38	Errore medio sui tre orizzonti di predizione con l'ottimizzatore e la funzione di loss selezionate in funzione del piano di riferimento - Approccio MIMO	125
4.39	Errore medio in funzione dei tre orizzonti di predizione con l'ottimizzatore e la funzione di loss selezionate e in funzione del piano di riferimento - Approccio MIMO	125
4.40	Errore medio sui tre orizzonti di predizione e sui tre piani con l'ottimizzatore e la funzione di loss selezionate in funzione dell'ufficio di riferimento - Approccio MIMO	126
4.41	Errore medio per ciascun piano e per ciascun intervallo di predizione in funzione dell'approccio	127
4.42	Temperature effettive e predette - orizzonte di predizione di 2 ore - test set P1R38 - Approccio MIMO	128
4.43	Temperature effettive vs predette - orizzonte di predizione di 2 ore - test set P1R38 - Approccio MIMO	129
4.44	Temperature effettive e predette - orizzonte di predizione di 2 ore - test set P1R39 - Approccio MIMO	130
4.45	Temperature effettive vs predette - orizzonte di predizione di 2 ore - test set P1R39 - Approccio MIMO	131
4.46	Temperature effettive e predette - orizzonte di predizione di 2 ore - test set P1R40 - Approccio MIMO	132
4.47	Temperature effettive vs predette - orizzonte di predizione di 2 ore - test set P1R40 - Approccio MIMO	133
4.48	Temperature effettive e predette - orizzonte di predizione di 2 ore - test set P1R42 - Approccio MIMO	134
4.49	Temperature effettive vs predette - orizzonte di predizione di 2 ore - test set P1R42 - Approccio MIMO	135
4.50	Temperature effettive e predette - orizzonte di predizione di 2 ore - test set P1R45 - Approccio MIMO	136
4.51	Temperature effettive vs predette - orizzonte di predizione di 2 ore - test set P1R45 - Approccio MIMO	137
4.52	Temperature effettive e predette - orizzonte di predizione di 2 ore - validation set P1R38 - Approccio MIMO	138
4.53	Temperature effettive vs predette - orizzonte di predizione di 2 ore - validation set P1R38 - Approccio MIMO	139
4.54	Temperature effettive e predette - orizzonte di predizione di 2 ore - validation set P1R39 - Approccio MIMO	140

4.55	Temperature effettive vs predette - orizzonte di predizione di 2 ore - validation set P1R39 - Approccio MIMO	141
4.56	Temperature effettive e predette - orizzonte di predizione di 2 ore - validation set P1R40 - Approccio MIMO	142
4.57	Temperature effettive vs predette - orizzonte di predizione di 2 ore - validation set P1R40 - Approccio MIMO	143
4.58	Temperature effettive e predette - orizzonte di predizione di 2 ore - validation set P1R42 - Approccio MIMO	144
4.59	Temperature effettive vs predette - orizzonte di predizione di 2 ore - validation set P1R42 - Approccio MIMO	145
4.60	Temperature effettive e predette - orizzonte di predizione di 2 ore - validation set P1R45 - Approccio MIMO	146
4.61	Temperature effettive vs predette - orizzonte di predizione di 2 ore - validation set P1R45 - Approccio MIMO	147
4.62	Temperature effettive e predette - orizzonte di predizione di 2 ore - test set P2R38 - Approccio MIMO	148
4.63	Temperature effettive vs predette - orizzonte di predizione di 2 ore - test set P2R38 - Approccio MIMO	149
4.64	Temperature effettive e predette - orizzonte di predizione di 2 ore - test set P2R39 - Approccio MIMO	150
4.65	Temperature effettive vs predette - orizzonte di predizione di 2 ore - test set P2R39 - Approccio MIMO	151
4.66	Temperature effettive e predette - orizzonte di predizione di 2 ore - test set P2R40 - Approccio MIMO	152
4.67	Temperature effettive vs predette - orizzonte di predizione di 2 ore - test set P2R40 - Approccio MIMO	153
4.68	Temperature effettive e predette - orizzonte di predizione di 2 ore - test set P2R42 - Approccio MIMO	154
4.69	Temperature effettive vs predette - orizzonte di predizione di 2 ore - test set P2R42 - Approccio MIMO	155
4.70	Temperature effettive e predette - orizzonte di predizione di 2 ore - test set P2R45 - Approccio MIMO	156
4.71	Temperature effettive vs predette - orizzonte di predizione di 2 ore - test set P2R45 - Approccio MIMO	157
4.72	Temperature effettive e predette - orizzonte di predizione di 2 ore - validation set P2R38 - Approccio MIMO	158
4.73	Temperature effettive vs predette - orizzonte di predizione di 2 ore - validation set P2R38 - Approccio MIMO	159
4.74	Temperature effettive e predette - orizzonte di predizione di 2 ore - validation set P2R39 - Approccio MIMO	160

4.75	Temperature effettive vs predette - orizzonte di predizione di 2 ore - validation set P2R39 - Approccio MIMO	161
4.76	Temperature effettive e predette - orizzonte di predizione di 2 ore - validation set P2R40 - Approccio MIMO	162
4.77	Temperature effettive vs predette - orizzonte di predizione di 2 ore - validation set P2R40 - Approccio MIMO	163
4.78	Temperature effettive e predette - orizzonte di predizione di 2 ore - validation set P2R42 - Approccio MIMO	164
4.79	Temperature effettive vs predette - orizzonte di predizione di 2 ore - validation set P2R42 - Approccio MIMO	165
4.80	Temperature effettive e predette - orizzonte di predizione di 2 ore - validation set P2R45 - Approccio MIMO	166
4.81	Temperature effettive vs predette - orizzonte di predizione di 2 ore - validation set P2R45 - Approccio MIMO	167
4.82	Temperature effettive e predette - orizzonte di predizione di 2 ore - test set P3R38 - Approccio MIMO	168
4.83	Temperature effettive vs predette - orizzonte di predizione di 2 ore - test set P3R38 - Approccio MIMO	169
4.84	Temperature effettive e predette - orizzonte di predizione di 2 ore - test set P3R39 - Approccio MIMO	170
4.85	Temperature effettive vs predette - orizzonte di predizione di 2 ore - test set P3R39 - Approccio MIMO	171
4.86	Temperature effettive e predette - orizzonte di predizione di 2 ore - test set P3R40 - Approccio MIMO	172
4.87	Temperature effettive vs predette - orizzonte di predizione di 2 ore - test set P3R40 - Approccio MIMO	173
4.88	Temperature effettive e predette - orizzonte di predizione di 2 ore - test set P3R42 - Approccio MIMO	174
4.89	Temperature effettive vs predette - orizzonte di predizione di 2 ore - test set P3R42 - Approccio MIMO	175
4.90	Temperature effettive e predette - orizzonte di predizione di 2 ore - test set P3R45 - Approccio MIMO	176
4.91	Temperature effettive vs predette - orizzonte di predizione di 2 ore - test set P3R45 - Approccio MIMO	177
4.92	Temperature effettive e predette - orizzonte di predizione di 2 ore - validation set P3R38 - Approccio MIMO	178
4.93	Temperature effettive vs predette - orizzonte di predizione di 2 ore - validation set P3R38 - Approccio MIMO	179
4.94	Temperature effettive e predette - orizzonte di predizione di 2 ore - validation set P3R39 - Approccio MIMO	180

4.95	Temperature effettive vs predette - orizzonte di predizione di 2 ore - validation set P3R39 - Approccio MIMO	181
4.96	Temperature effettive e predette - orizzonte di predizione di 2 ore - validation set P3R40 - Approccio MIMO	182
4.97	Temperature effettive vs predette - orizzonte di predizione di 2 ore - validation set P3R40 - Approccio MIMO	183
4.98	Temperature effettive e predette - orizzonte di predizione di 2 ore - validation set P3R42 - Approccio MIMO	184
4.99	Temperature effettive vs predette - orizzonte di predizione di 2 ore - validation set P3R42 - Approccio MIMO	185
4.100	Temperature effettive e predette - orizzonte di predizione di 2 ore - validation set P3R45 - Approccio MIMO	186
4.101	Temperature effettive vs predette - orizzonte di predizione di 2 ore - validation set P3R45 - Approccio MIMO	187

Glossario

MPC

Model Predictive Control

AI

Artificial Intelligence

HVAC

Heating Ventilation and Air Conditioning

BMS

Building Management System

IoT

Internet Of Things

RC

Resistance Capacitance

ARX

AutoRegressive with the eXogenous

ARIMA

AutoRegressive Integrated Moving Average

ARMAX

AutoRegressive Moving Average with eXogenous

MARS

Multivariate Adaptive Regression Splines

Lasso

Least Absolute Shrinkage and Selection Operato

RNN

Recursive Neural Network

CNN

Convolutional Neural Network

LSM

Liquid State Machine

LSTM

Long Short Term Memory

GRU

Gated Recurrent Unit

BRNN

Bayesian Regularized Neural Network

MLP

Multi Layer Perceptron

AvNN

Average Neural Network

GRNN

General Regression Neural Network

ELM

Extreme Learning Machine

DNN

Deep belief Neural Network

NARX

Nonlinear AutoRegressive models with eXogenous input

GrTree

Gradient Boosting Regression Tree

GBM

Generalized Boosted Model

SVM

Support Vector Machine

GrLR

Gradient Boosting Linear Regressor

RMSE

Root Mean Squared Error

NRMSE

Normalized Root Mean Squared Error

MAE

Mean Absolute Error

L-M

Levenberg-Marquardt

SCG

Scaled Conjugate Gradient

MLR

Multiple Linear Regression

MIMO

Multi Input Multi Output

MISO

Multi Input Single Output

SMAPE

Symmetric Mean Absolute Percentage Error

MAPE

Mean Absolute Percentage Error

VAV

Variabile Air Volume

MRE

Mean Relative Error

RBF

Radial Basis Function

SGD

Stochastic Gradient Descent

UTA

Unità Trattamento Aria

Capitolo 1

L'intelligenza artificiale per l'efficientamento energetico

Questo capitolo si pone l'obiettivo di illustrare le ragioni della necessità di introdurre strumenti che consentano di ottimizzare il consumo energetico negli edifici, sottolineando i principali benefici in ambito politico, tecnologico, sociale ed economico che un utilizzo efficiente e razionale delle fonti di energia derivato da applicazioni di tecnologie di intelligenza artificiale potrebbe assicurare.

1.1 Le sfide dell'efficientamento energetico

Negli ultimi anni, l'interesse nei confronti di un utilizzo efficiente dell'energia negli edifici è cresciuto in modo considerevole. Sono stati diversi i fattori che hanno contribuito alla prioritizzazione di questo obiettivo. Il settore immobiliare, negli stati membri dell'Unione Europea, è infatti responsabile di una significativa percentuale del consumo energetico totale, una quota mantenutasi costante negli anni, fino a sfiorare a volte il 40% del totale, come si evince osservando il relativo grafico (Figura 1.1). In aggiunta, dal momento che si tratta di un settore in forte crescita, questa quota è solo destinata ad aumentare. Non si tratta soltanto di una crescita in termini dimensionali: si è registrato anche un innalzamento degli standard di comfort per gli occupanti. In generale, un alto livello di well-being per gli occupanti, che include il comfort termico, il comfort visivo e una buona qualità dell'aria indoor, richiede un alto dispendio di energia. Il target diventa quindi riuscire a conciliare il risparmio energetico con la massimizzazione del benessere degli occupanti, un trade off sicuramente non facile da raggiungere. Anche la gestione dei picchi di carico, legati al sempre più massiccio ricorso ad impianti ad aria condizionata, è un'ulteriore causa di inefficienza che mette alla prova i sistemi

di produzione.

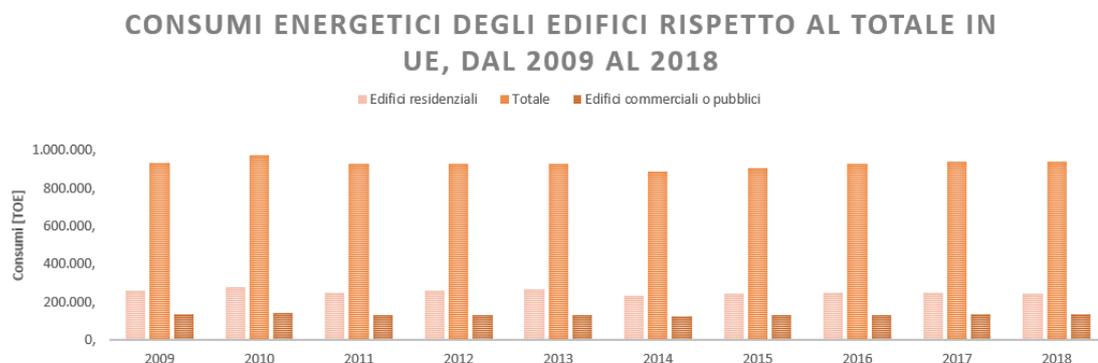


Figura 1.1: Consumi energetici del settore immobiliare rispetto al totale in UE [Fonte Eurostat]

A livello mondiale la situazione non cambia, il settore si riconferma come uno dei più esigenti in termini di energia, come si osserva in figura 1.2. Secondo il report globale relativo agli edifici e alle costruzioni preparato dall'International Energy Agency (IEA) per la Global Alliance for Buildings and Construction (GlobalABC) nel 2019[3], questa quota è stata registrata in aumento del 1% nel 2018 rispetto all'anno precedente, e circa del 7% rispetto al 2010. Questa forte crescita è da imputarsi principalmente alla rapida crescita della popolazione, ma anche a un incremento costante della domanda di elettricità di soddisfare. La quota di energia destinata agli edifici, infatti, è destinata principalmente alla generazione di elettricità e alla climatizzazione.

Al consumo di energia legato al settore contribuiscono in modo abbastanza paritario gli edifici di tipo residenziale e quelli ad uso commerciale. In termini di gestione energetica, si tratta di scenari divergenti, in quanto nel caso residenziale gli input sono sotto il controllo arbitrario di singoli individui, i picchi si verificano tipicamente durante la serata e i trend di consumo sono meno prevedibili; inoltre, la presenza degli utenti nelle ore notturne rende limitata la possibilità di preconditioning. Al contrario, la gestione centralizzata per gli edifici commerciali, la maggiore consistenza dei trend, la maggiore libertà in termini di scheduling e di manipolazione delle variabili in input e altre caratteristiche specifiche che facilitano l'individuazione di pattern rendendo così la possibilità di ottimizzare il consumo un obiettivo più concreto sono ragioni per cui la maggior parte degli sforzi di ricerca per modelli predittivi con l'obiettivo di un miglior management energetico si è concentrata su questa tipologia di edifici.

Sono diverse le considerazioni riconducibili alle evidenze illustrate.

Innanzitutto, il crescente bisogno di ricorrere allo sfruttamento delle fonti di energia

QUOTE DI CONSUMO DI ENERGIA PER SETTORE A LIVELLO GLOBALE

■ Trasporti ■ Altro ■ Costruzioni ■ Industria ■ Residenziale ■ Non residenziale

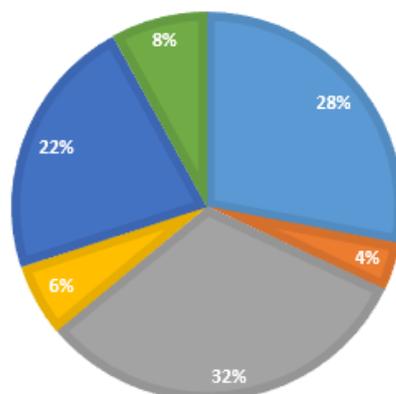
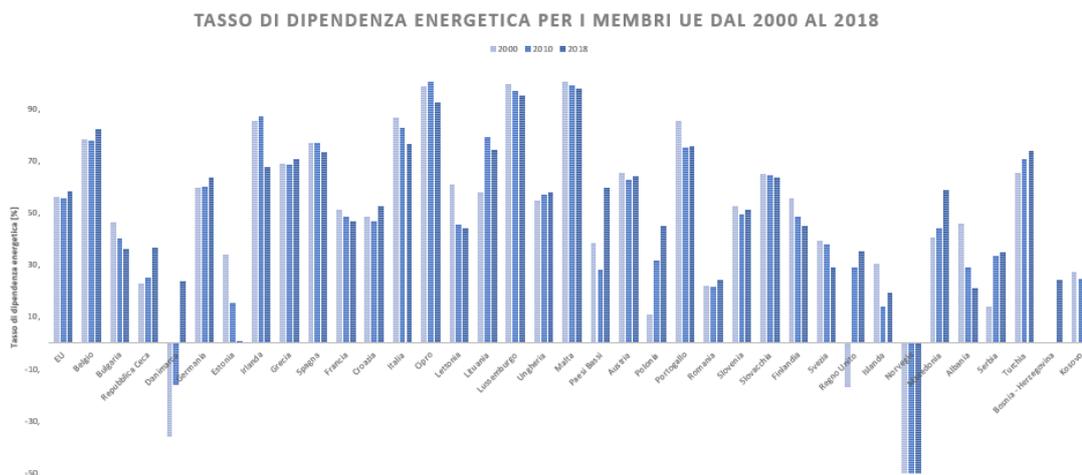


Figura 1.2: Quote di consumo di energia per settore a livello globale [Fonte IEA]]

non rinnovabile, a causa della domanda in costante aumento, continua a spingerne verso l'alto il prezzo di mercato, come è ben noto nel caso del petrolio. D'altro canto, le risorse non rinnovabili non possono ricrearsi con un ritmo sufficiente per stare al passo con i consumi; la loro sempre minore disponibilità è un fattore di preoccupazione non trascurabile. Risulta quindi evidente la necessità pratica e urgente di svincolarsi dalla dipendenza da questo tipo di fonti di energia, la cui permanenza in futuro sembra non essere più una certezza. La necessità ha un carattere anche politico: una delle principali criticità oggetto di dibattito per molti paesi dell'Unione Europea è la dipendenza energetica, ossia il bisogno di ricorrere alle importazioni per soddisfare il proprio fabbisogno energetico. Questo indicatore è calcolato come il rapporto fra il valore delle importazioni nette di energia e il consumo interno lordo di energia, comprendente i bunkeraggi. Un elevato grado di dipendenza energetica riflette spesso una vulnerabilità sul piano sia della sicurezza energetica, dal momento che la maggior parte dei paesi esportatori sono caratterizzati da una rischiosa instabilità geopolitica e potrebbero non garantire continuità nella fornitura, sia in termini economici. Il grafico a barre sottostante (figura 1.3) evidenzia come, benché il trend risulti decrescente nel tempo, il problema accomuna quasi tutti gli stati membri, raggiungendo occasionalmente situazioni limite, come spiacevolmente si può notare nel caso dell'Italia, con una percentuale di dipendenza energetica che sfiora il 76%. Esistono poi delle eccezioni in cui il tasso di dipendenza energetica assume perfino un valore negativo: un caso eclatante è quello della Norvegia, con un risultato che oltrepassa il -700%.



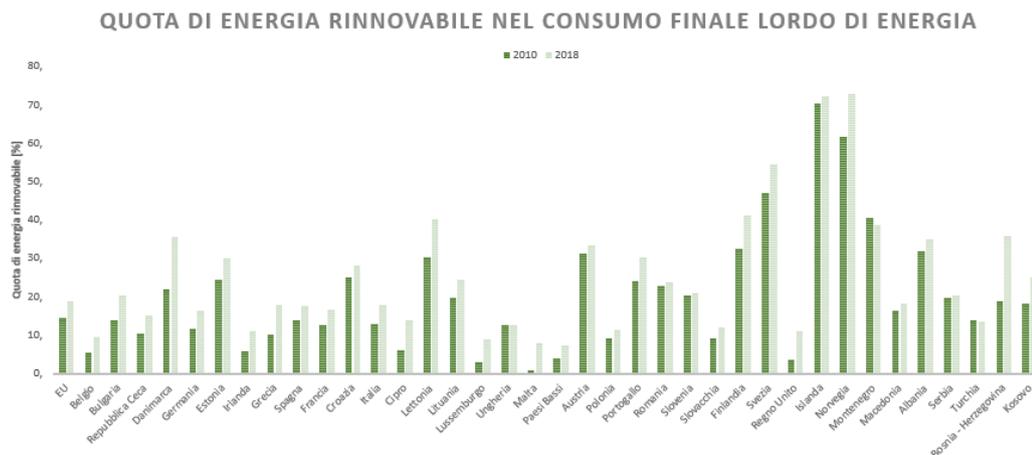


Figura 1.4: Quota di energia rinnovabile nel consumo finale lordo di energia per gli stati membri dell'Unione Europea dal 2010 al 2018 [Fonte Eurostat]

come l'accessibilità, la sicurezza e lo scopo di utilizzo dell'edificio". Si conclude affermando che "è responsabilità dei soli Stati Membri di fissare dei requisiti minimi per le performance energetiche degli edifici, requisiti fissati raggiungendo un equilibrio tra l'ottimo nei costi tra gli investimenti e i costi energetici risparmiati" [1], e sottolineando così l'importanza e l'urgenza del problema, il cui superamento rappresenterà un passo significativo per il progresso tecnico.

Si propone una rappresentazione delle varie sfaccettature del problema sottoforma di un albero del problema (figura 1.5), un metodo che consente di definire un core problem, la radice dell'albero, a cui si giunge tramite concatenazioni di relazioni causa-effetto di problemi precedenti, e da cui si diramano ulteriori conseguenze. La formulazione dei vari aspetti del problema è stata ritenuta importante per poter offrire un quadro riassuntivo completo.

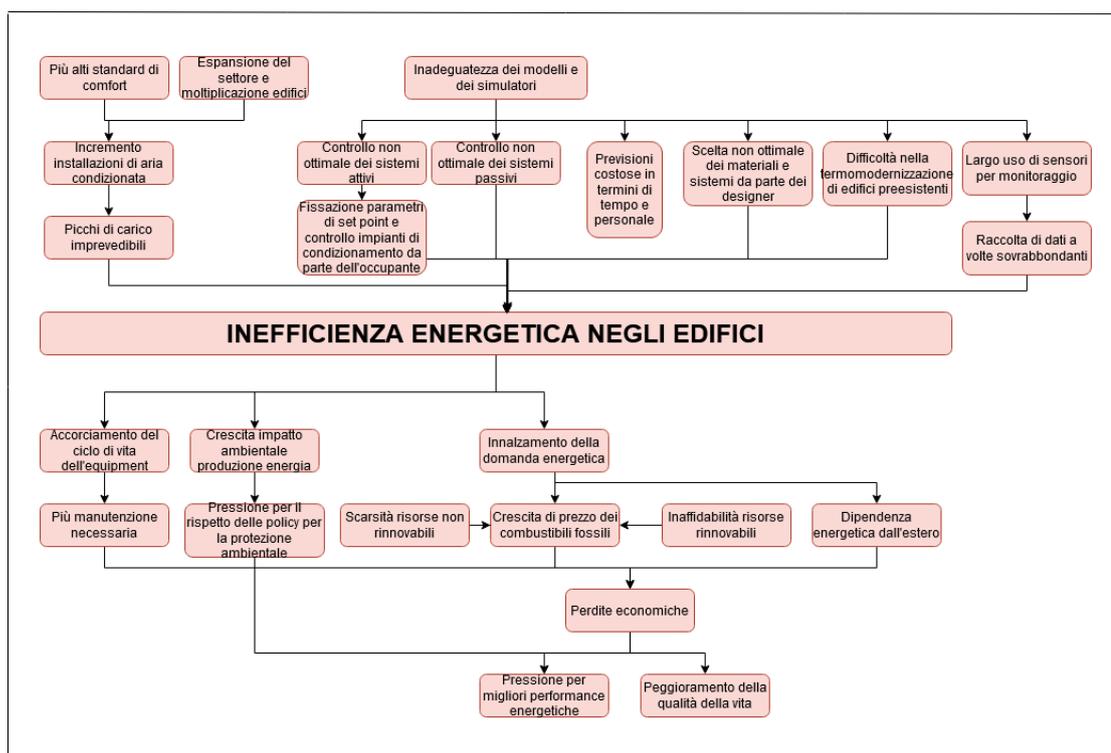


Figura 1.5: Albero del problema che riassume le sfaccettature delle criticità che si intende alleviare

1.2 Principali benefici dell'applicazione di strategie di Model Predictive Control al settore

Le osservazioni elencate finora dimostrano che lo scenario in questione è uno dei rari in cui le esigenze ambientali, politiche ed economiche sono perfettamente allineate, in accordo anche con l'utilità del singolo, che a fronte di una minimizzazione dei consumi potrebbe beneficiare di una migliore qualità della vita.

L'esigenza di poter usufruire di modelli efficaci viene confermata nella stessa Direttiva, dove vengono suggeriti modelli che includano, "in aggiunta alle caratteristiche termiche, altri fattori che giocano un ruolo sempre più importante, come gli impianti di riscaldamento e di aria condizionata, le applicazioni di energia da fonti rinnovabili, gli elementi passivi di riscaldamento e raffreddamento, l'ombreggiatura, la qualità dell'aria interna, un'adeguata luce naturale e il design dell'edificio".

Uno dei principali deterrenti per la realizzazione di edifici energeticamente efficienti è l'impossibilità di prevederne il consumo energetico. Per questa finalità sono stati

sviluppati adeguati simulatori, che sono in grado di effettuare previsioni piuttosto accurate e che di solito riescono a tenere in considerazione la maggior parte dei fenomeni complessi che influenzano il comportamento degli edifici nella determinazione delle performance energetiche. D'altro canto, però, si rivelano spesso inadeguati a causa dei tempi computazionali del tutto proibitivi, della complessità d'uso e dell'impossibilità di identificare e confrontare l'influenza delle variabili sui parametri osservati per la valutazione della performance energetica. Per incrementare l'accuracy previsionale, la letteratura propone varie tecniche di machine learning che potrebbero apportare un contributo decisivo, permettendo di monitorare e analizzare ampi volumi di dati con il minimo sforzo, con l'ausilio degli opportuni sensori, e riuscendo così a sfruttare anche le potenzialità del mondo dell'Internet of Things, un altro contesto beneficiario di un vertiginoso progresso negli ultimi anni. Il machine learning è una branca dell'intelligenza artificiale, oggigiorno utilizzata in innumerevoli ambiti. L'analisi di serie storiche dell'energia consumata da un edificio, infatti, rende possibile individuare trend e pattern, oltre che la predizione delle variabili che definiscono il consumo di energia nell'edificio. La temperatura è tra queste la più rilevante perché influenza le operazioni dei sistemi di raffrescamento in estate e di riscaldamento in inverno, oltre ad essere il principale parametro che definisce il comfort ambientale. In questo ambito, frequentemente vengono utilizzate le tecniche di support vector regression, reti neurali artificiali, alberi di regressione, random forest, chi squared automatic interaction detector, regressori lineari generali e sistemi ibridi.

L'intelligenza artificiale ha importanti applicazioni anche nella semplificazione e ottimizzazione della progettazione dell'edificio. In questo caso, le metodologie expert system e case based reasoning system rivestono un ruolo di primo piano. Le prime rientrano nella categoria dei modelli di regressione di tipo rule-based, nello specifico caso del design di edifici vengono chiamati Intelligent Design Support Model e consentono la consultazione di un database dove vengono immagazzinate informazioni riguardanti le regolazioni, gli impianti e le architetture che garantiscono il rispetto dei migliori standard energetici, così da poter vagliare rapidamente il maggior numero di alternative. Le seconde prevedono a loro volta la creazione di database, popolati attraverso la somministrazione di questionari tramite i quali gli architetti definiscono i range di validità per ogni variabile linguistica, ossia una caratteristica strutturale. Ogni variabile è assegnata a un fuzzy set, che possa descriverne i valori. Gli utilizzatori accedono al database tramite query per ricercare le soluzioni preesistenti le cui variabili linguistiche più si avvicinano al range richiesto dall'investitore, apportano le adeguate modifiche alla soluzione preesistente, e inseriscono la nuova proposta nel database.

Un'altra applicazione viene riscontrata non soltanto nella costruzione di nuove infrastrutture, ma anche nella cosiddetta termomodernizzazione, soprattutto se riguarda gruppi di edifici. Il principio del rimborso autonomo consiste nell'utilizzare

le risorse disponibili dell'investitore prima nell'edificio con il costo di rimborso più corto, ossia quello che remunera prima l'investimento tramite il taglio di costi energetici avvenuti in seguito alla modernizzazione. La strategia di investimento che garantisce il termine del processo e il minor costo possibile si basa spesso, infatti, su algoritmi genetici.

Un'ulteriore difficoltà che coinvolge l'efficienza energetica degli edifici e che è diventata un campo di prova per le tecniche di intelligenza artificiale sono le operazioni di ventilazione, riscaldamento e condizionamento e la diagnosi dei guasti. Poiché è stato dimostrato che i sistemi HVAC sono la maggior fonte di consumo energetico negli edifici, configurarne correttamente i parametri basandosi su un modello di machine learning affidabile e in grado di prendere in considerazione i fattori esterni diventa una questione di primaria importanza. A questo fine, le soluzioni più indicate sono spesso reti neurali artificiali, logiche fuzzy, algoritmi genetici ed expert system, ma sono presenti anche proposte che includono le tecniche di reinforcement learning, dove si ottengono dei controller che possiedono una conoscenza di base dell'edificio e che la incrementano continuamente nel tempo, e che hanno mostrato performance migliori rispetto ai controller di tipo fuzzy-PD e i tradizionali controller on-off. In questi casi, gli expert system, invece, includono sia soluzioni di tipo diagnostic tool, sia sistemi che combinano la conoscenza con moli di dati per ottimizzare l'illuminazione e in generale la conservazione dell'energia, sia approcci knowledge-based che si occupano della regolazione per garantire efficienza nei consumi e comfort per gli occupanti in base alla previsione delle loro attività nell'edificio. Si tratta di modelli che non si pongono come obiettivo una previsione, ma la minimizzazione di una funzione obiettivo, di solito il consumo, con riguardo di massimizzare le funzioni di qualità dell'aria interna e di comfort termico, ricevendo in input le preferenze dell'occupante e restituendo come output una strategia di controllo ottimale. Interventi di questo genere conducono ai benefici più svariati:

- Sarebbe possibile un contenimento degli sprechi energetici. L'energia viene consumata in modo eccessivo negli edifici e nei sistemi HVAC a causa di failure, dovute ad esempio a inappropriate temperature di set point o di errati apporti di aria esterna, cause tra l'altro anche di discomfort per gli occupanti. La gestione dei sistemi attivi, dove con questo termine si intendono sistemi che si avvalgono di mezzi meccanici per coprire il fabbisogno energetico, e congiuntamente la gestione dei sistemi passivi, che includono i sistemi che sfruttano le caratteristiche del sito e dell'edificio per ricreare le condizioni climatiche desiderate, senza ricorrere a mezzi artificiali, sono subordinate al rispetto dei parametri fissati come set point dall'occupante, che si occupa anche personalmente dell'accensione/spegnimento dei sistemi di condizionamento; prevedendo l'andamento delle variabili interne sulla base delle condizioni esterne, sarebbe possibile elaborare strategie di preriscaldamento o preraffreddamento, ma anche, attraverso l'apprendimento dei parametri legati al

comportamento dell'utente, adeguare, sempre nell'ottica della minimizzazione degli sprechi senza inficiare il comfort percepito, la variabile controllata in modo opportuno. L'obiettivo è quello di raggiungere un contesto di smart building: interni intelligenti che reagiscono con le condizioni naturali esterne, anticipandone i comportamenti. Ci si riferisce con il termine generico home automation al set di servizi che soddisfano le esigenze di sicurezza, comunicazione, gestione dell'energia e del comfort di un occupante e del suo immediato ambiente circostante; si tratta quindi di una disciplina in grado di integrare le tecnologie informatiche nel design delle infrastrutture, e che necessita di tecniche di predizione accurate. A giovarne sarebbe anche l'equipment, primi fra tutti i refrigeratori, che sarebbero in grado di anticipare i cambiamenti nella temperatura e minimizzare di conseguenza le oscillazioni interne. L'effetto congiunto di una minore spesa in elettricità, un ciclo di vita più espanso per l'equipment e di conseguenza inferiori costi di switching e di manutenzione, un raggiungimento automatico del livello di comfort richiesto e una maggiore consapevolezza da parte del consumatore o dell'organizzazione sui propri consumi non può che tradursi a un indiscutibile impatto positivo sulla qualità di vita, permettendo eventualmente di trasformare il dato in informazione e prendere delle decisioni a riguardo.

- Le informazioni sulla previsione del consumo provenienti da diversi edifici potrebbero essere aggregate e permettere la predizione dei consumi di aree più vaste, di città, addirittura di stati. Sarebbe possibile una più razionale gestione della produzione di energia ad alto livello, che potrebbe facilitare la transizione verso le fonti rinnovabili, superando eventualmente il limite della loro inaffidabilità. Una produzione ottimizzata in termini qualitativi e quantitativi impatterebbe meno sui sistemi ecologici e consentirebbe un maggiore allineamento agli obiettivi di sostenibilità fissati dal Protocollo di Kyoto.
- Molti stati potrebbero in parte svincolarsi dalla dipendenza dalle risorse non rinnovabili e riuscire così a diminuire il loro grado di dipendenza energetica, modificando gli equilibri del mercato globale e ottenendo una maggiore sicurezza riguardo alla fornitura di energia nel medio e lungo periodo.
- Il continuo monitoraggio delle performance sarebbe condotto senza eccedere in spese di attrezzatura, avvalendosi di un numero ragionevole di sensori ed evitando la raccolta di dati ridondanti o non essenziali. La presenza di un database costituito da dati di qualità consentirebbe non solo di migliorare sempre più l'accuratezza dei modelli, ma anche ai designer di individuare configurazioni, materiali e sistemi energetici più performanti, evitando il costo di analisi di molte soluzioni alternative, senza d'altro canto trascurare

le infrastrutture già presenti, su cui sarebbero possibili, come già descritto, efficaci interventi di energy conservation.

Le prospettive future che ci si auspica di raggiungere modellano uno scenario di Ambient Intelligence: un paradigma incentrato sull'utente e basato su tre tecnologie altamente innovative: la comunicazione costante, il computing costante, l'interfaccia utente intelligente. Tale ambiente digitale è in grado di percepire la presenza degli utenti e adeguarsi alle loro necessità, interpretate a partire dal loro comportamento. Il funzionamento si basa su uno strato operativo, che include ad esempio la componente hardware, il database e i sistemi di comunicazione fra i vari componenti, e uno strato intelligente, rappresentato dalle varie metodologie di intelligenza artificiale integrate che concorrono al funzionamento globale.

Il ruolo dell'Internet of Things, come anticipato, potrebbe a sua volta rivelarsi cruciale. Gli edifici sono via via sempre più monitorati, con obiettivi di controllo, regolazione, sicurezza, diagnosi, e raggiungimento di una conduzione intelligente. I sensori associati a un sistema wireless hanno raggiunto ormai costi medi bassissimi, meno di \$2, sono facili da installare e generano un'enorme quantità di dati, perdipiù integrati dall'interazione con gli occupanti (ad esempio via smartphone o altre interfacce), che vengono centralizzati da attuatori che a loro volta hanno raggiunto costi assolutamente non proibitivi (ad esempio 50 euro per un nano-computer raspberry pi type). Le tecnologie standard di comunicazione prevedono la classica local area network (LAN) o wireless (WLAN) per gli edifici residenziali, mentre per gli altri vengono utilizzati specifici protocolli (e.g. DALI per l'illuminazione, MDBUS e KNX per il piccolo terziario, o LON e BACNET per gli edifici relativamente grandi), che principalmente sono aperti e permettono un'interoperabilità fra diversi sistemi più facile da raggiungere che per il sistema proprietario del wireless. La diffusione di soluzioni aperte per l'interconnessione, anche fra aziende consolidate, non ha fatto che incrementare un trend già in ascesa; secondo IDATE (Institute for Audiovisual and Telecommunications in Europe) ci saranno 35 bilioni di oggetti connessi, 4 volte la popolazione mondiale, nel 2030 contro i 4 bilioni del 2010[6]. Si stanno diffondendo servizi come BMS (Building Management System) che aggregano set di sensori più o meno vasti. Essi permettono la visualizzazione dei dati in vari formati e grafici, analisi di dati che permettono di identificare correlazioni fra variabili, di limitare le incertezze di misura, di ricostruire i dati mancanti nei periodi di malfunzionamento e di operare i necessari confronti.

Per riassumere, sono davvero numerose le opportunità praticabili grazie ad un'accurata capacità di predire la temperatura all'interno degli edifici, tutte principalmente derivate dalla possibilità di instaurare policy di controllo, nell'ottica di gestione della domanda, di una gestione delle variabili controllate sulla base delle predizioni (Model Predictive Control), della stima della domanda e della risposta, e di uno scheduling ottimale del sistema.

Anche in questo caso si conclude con una rappresentazione grafica e intuitiva in

grado di riassumere tutte le concatenazioni causa-effetto più salienti nello scenario di applicazione di modelli basati sull'intelligenza artificiale in campo infrastrutturale. Come il precedente poteva essere definito come un albero del problema, in questo caso si può parlare di un albero della soluzione (figura 1.6), in grado di riassumere le principali dinamiche legate all'introduzione di modelli semplici ed efficaci basati sulle tecniche di intelligenza artificiale e di ricondurle a una singola chiave di volta che identifica un effetto primario e dominante da cui si diramano le altre conseguenze.

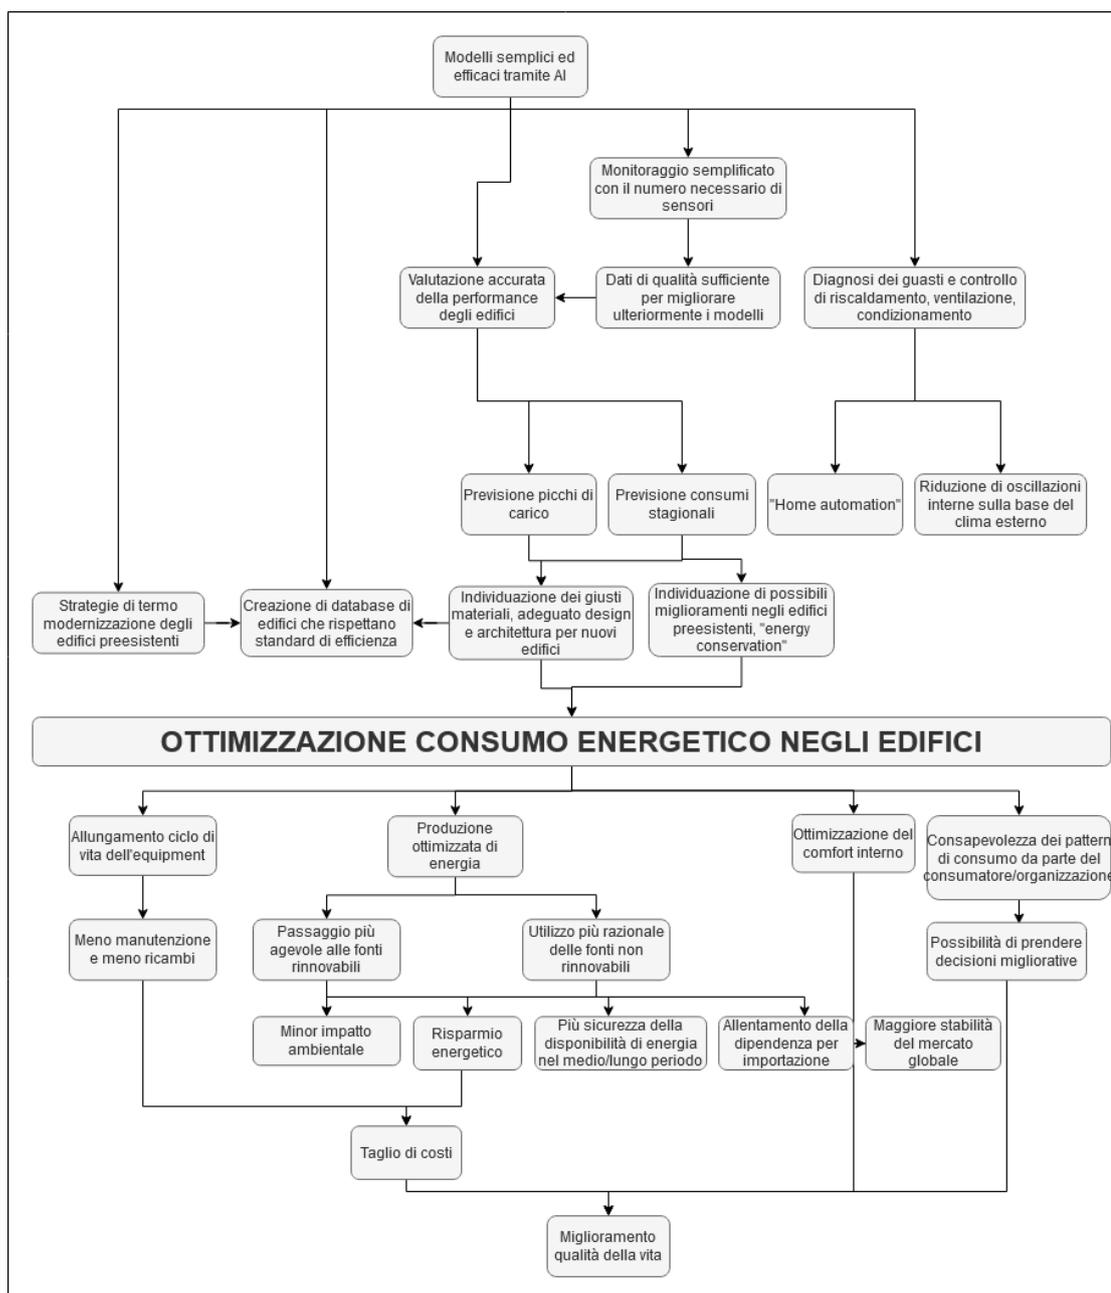


Figura 1.6: Albero della soluzione che riassume gli effetti derivanti da un utilizzo dei modelli AI-based in campo edilizio]

1.2.1 AI per il raffrescamento dei data center: il caso Google

Da sempre pioniere nella sperimentazione di tecnologie innovative, il caso Google rappresenta un esempio di un'applicazione delle tecnologie di intelligenza artificiale alle infrastrutture riuscita con pieno successo. L'iniziativa risale al 2016 e nasceva per soddisfare l'esigenza di garantire un adeguato raffrescamento ai data center, che presentava alcune problematiche, per diverse ragioni:

- L'interazione fra i componenti presenti all'interno, caratterizzata da una forte imprevedibilità, complessità e non linearità, quindi difficile da quantificare e tenere successivamente in considerazione.
- La latenza delle infrastrutture nell'adeguarsi ai cambiamenti interni o esterni.
- L'unicità di ogni struttura, che rende difficoltosa se non impossibile la creazione di un modello universalmente valido.

Il tentativo ha richiesto due anni di applicazione degli algoritmi di machine learning. Sono stati utilizzati dati storici raccolti da migliaia di sensori posizionati all'interno del data center, riguardanti i più disparati parametri, ad esempio la temperatura, la potenza, la velocità delle pompe, al fine di permettere il training su diversi scenari operativi di un sistema di reti neurali artificiali. Dal momento che l'obiettivo rimaneva quello di raggiungere uno scenario di efficienza, il training è avvenuto sulla base di un indicatore chiamato PUE (Power Usage Effectiveness) e definito come il rapporto del consumo energetico totale dell'edificio rispetto al consumo energetico derivato dalle componenti IT. Fissandone il valore a quello desiderato, è stato possibile ricevere in output un suggerimento per la regolazione dei parametri operativi. Il testing è stato condotto osservando, all'interno di un data center, l'andamento nel tempo della variabile osservata, adeguando le variabili manipolate agli output forniti dal modello. Osservando il grafico sottostante (figura 1.7), che riporta l'andamento del PUE nel tempo, risulta evidente il dislivello fra lo scenario consueto e quello dove, invece, è stato tentato l'approccio basato sul machine learning. Il risultato è stato sbalorditivo: impostando i controlli come suggerito dal modello, si è diminuito il consumo di energia per il raffrescamento del 40%, a fronte di una diminuzione percentuale del PUE del 15%, nel complesso di gran lunga la migliore performance dimostrata dal data center.

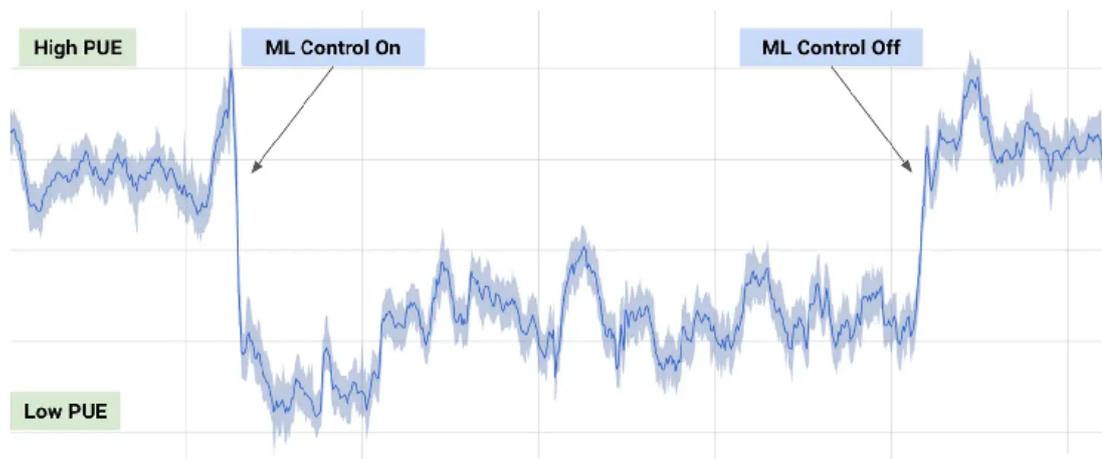


Figura 1.7: Andamento dell'indicatore PUE in funzione del tempo durante il testing dell'efficacia del modello avvenuto in un data center reale [Fonte deepmind.com][7]

Capitolo 2

Stato dell'arte

In questo capitolo si illustrano alcune delle proposte finora presentate di modelli adibiti alla predizione di parametri che descrivano, in modo più o meno completo, le condizioni ambientali degli interni di un'infrastruttura in base a determinate variabili in input e, di conseguenza, il fabbisogno energetico necessario a creare le adeguate circostanze per garantire il comfort degli occupanti. Vengono anche presentati i principali simulatori software, che rientrano nella categoria white box, disponibili in modalità turnkey in grado di generare un report riassuntivo delle performance energetiche in base agli input forniti.

2.1 Software di simulazione energetica

Nella seguente sezione e nelle relative sottosezioni, viene fornita una panoramica su alcuni dei software di simulazione energetica in uso allo stato attuale.

Questi strumenti offrono un valido supporto nella riduzione dei costi energetici negli edifici; sono infatti in grado di dimensionare i sistemi HVAC, analizzare il consumo energetico e calcolarne i conseguenti costi. Si rivelano particolarmente utili nella fase iniziale di progettazione dell'edificio, in modo da consentire ai designer di scartare le alternative meno performanti simulando il comportamento termico degli edifici tramite la predizione di variabili come la temperatura interna, l'apporto energetico richiesto per riscaldamento e raffrescamento, il consumo del sistema HVAC, il comfort degli occupanti, il livello di ventilazione, il quantitativo di luce naturale necessario. Inoltre, è possibile individuare il numero adeguato di dispositivi da collocare nelle stanze e la regolazione ottimale per garantire l'adeguato comfort simulandone, per quanto riguarda un buon numero di software, gli effetti congiunti. Per concludere, sono progettati per integrarsi molto facilmente con altri software e possono vantare una buona versatilità, grazie all'architettura di tipo modulare che è quella più frequentemente adottata in modo da rispettare le esigenze più

disparate.

L'innegabile vantaggio apportato da questo tipo di approccio è la possibilità di correggere eventuali errori già nello stadio iniziale e di evitare le ripercussioni economiche di scelte non efficienti, destinati soltanto a crescere in modo esponenziale con il trascorrere del tempo e il progredire dei lavori.

2.1.1 Utilizzo

La prima fase prevede l'inserimento delle coordinate all'interno del software, posizionate sulla base di un preciso riferimento, oppure utilizzare un file sorgente in un adeguato formato (ad esempio AutoCAD), così da ricreare il profilo dell'edificio. Successivamente, per rappresentare la struttura dell'edificio in maniera esauriente, è necessario specificare dimensioni e geometrie e selezionare i relativi materiali utilizzati, permettendo così al software di identificare i corretti valori per i parametri prestazionali. A titolo esemplificativo, si riportano le interfacce del software EnergyPlus; le figure 2.1 e 2.2 rappresentano le schermate di selezione e introduzione rispettivamente delle coordinate geometriche e dei materiali. Si

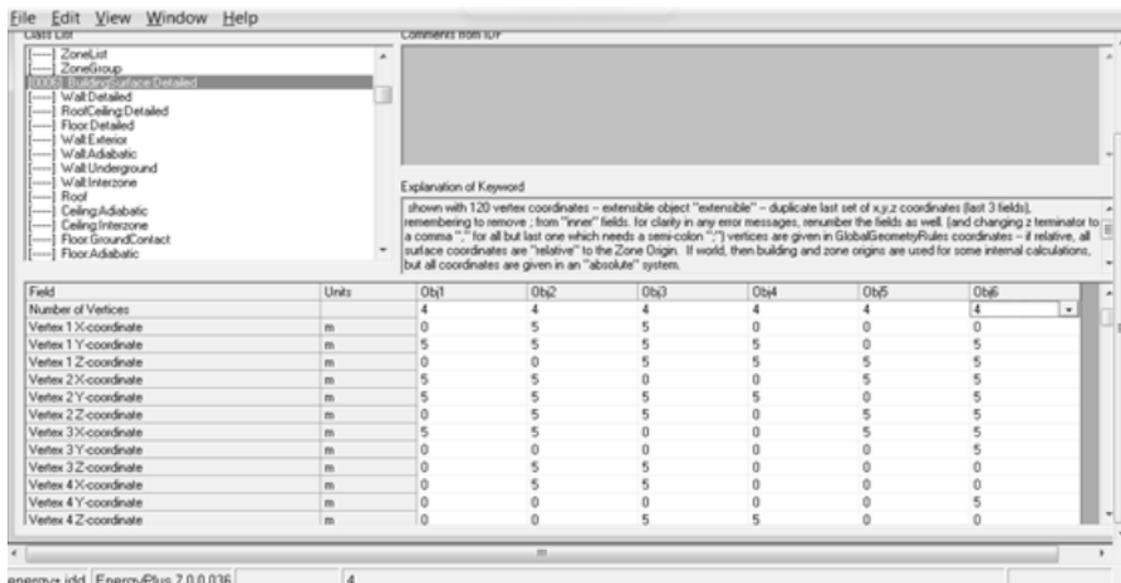


Figura 2.1: Interfaccia per l'inserimento delle coordinate nel software Energy Plus [Fonte Joana Sousa, Energy Simulation Software for Buildings: Review and Comparison][8]

procede così alla seconda fase, quella di simulazione vera e propria. Si specifica il tipo di edificio (etichettandolo come ufficio, o come residenziale, per esempio), l'equipment presente e il suo utilizzo quotidiano, e infine la presenza e le attività

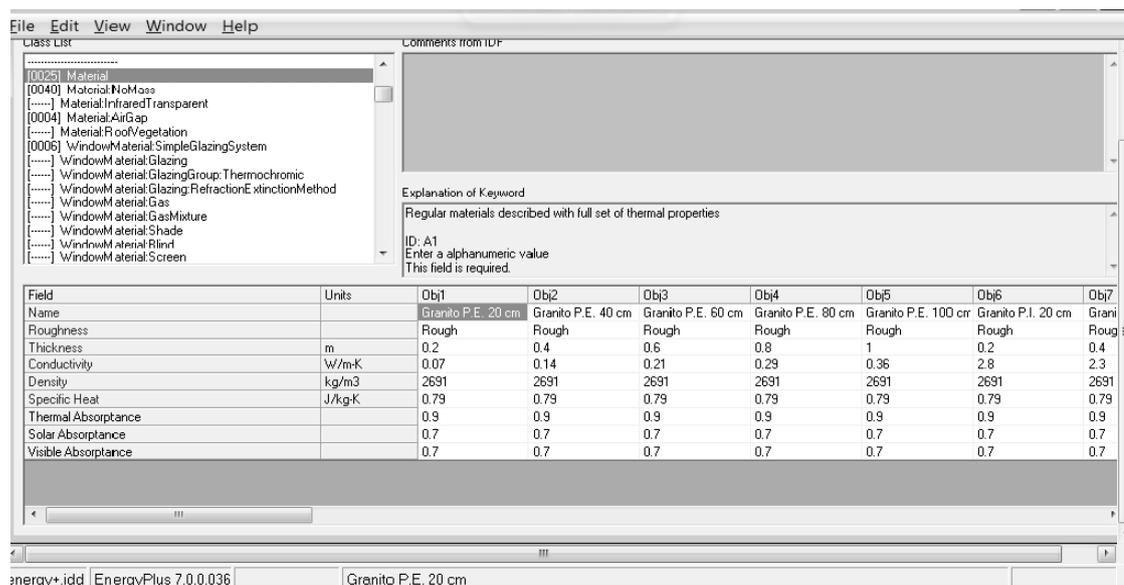


Figura 2.2: Interfaccia di selezione dei materiali utilizzati e delle loro proprietà nel software Energy Plus [Fonte Joana Sousa, Energy Simulation Software for Buildings: Review and Comparison][8]

umane nell'edificio, permettendo di avere sufficienti informazioni per determinare gli apporti interni e la ventilazione necessaria. Nel software Energy Plus, considerato qui come esempio, vengono aggiunti manualmente come "oggetti" dei modelli d'uso specificando per ciascun orario se l'edificio è in utilizzo o meno. Vengono poi aggiunte delle caratterizzazioni dei termostati, specificando per ciascuno il tipo di controllo fra le quattro modalità proposte. Altri dati da aggiungere sono una caratterizzazione degli influssi termici esterni, spesso ricavati da database come ASHRAE, mentre gli effetti dell'ombreggiatura vengono dedotti dalla geometria modellata.

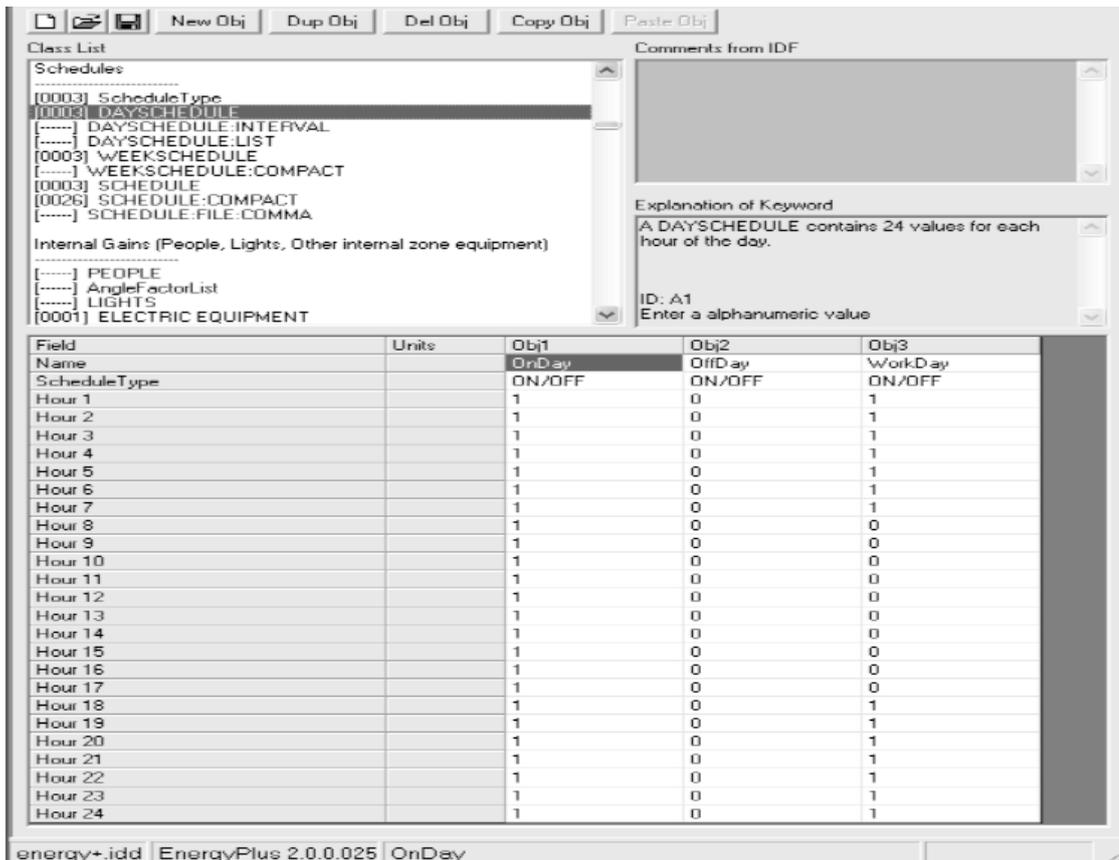


Figura 2.3: Interfaccia di aggiunta delle varie tipologie di day-schedule all'interno del software Energy Plus [Fonte Joana Sousa, Energy Simulation Software for Buildings: Review and Comparison][8]

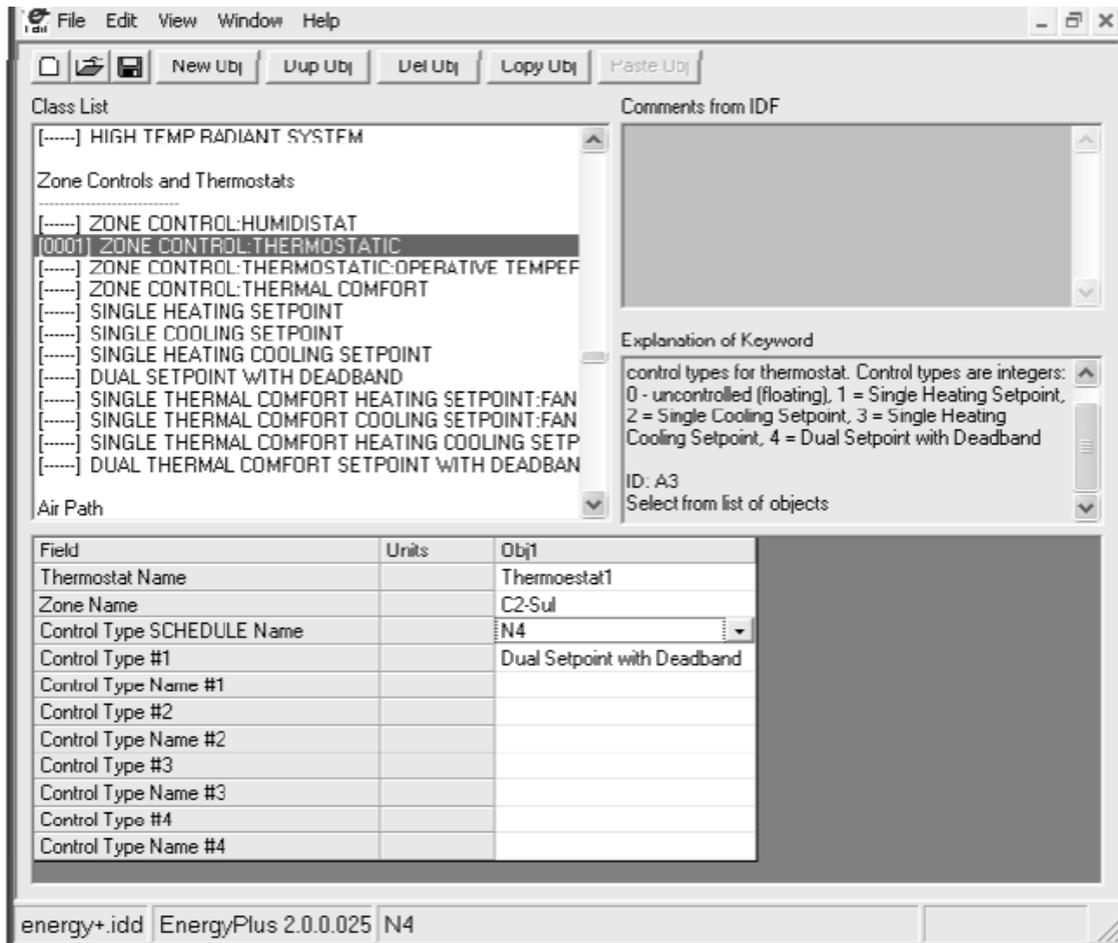


Figura 2.4: Interfaccia di aggiunta delle informazioni sui termostati per il software Energy Plus [Fonte Joana Sousa, Energy Simulation Software for Buildings: Review and Comparison][8]

Si conclude con l'analisi del risultato, cui si giunge valutando automaticamente le performance dei materiali e gli scambi energetici per conduzione, convezione e radiazione sulla base delle condizioni esterne e degli altri parametri in input. Nel complesso, i software sono in grado di generare output che vanno dai fenomeni fisici quali la distribuzione dell'aria, la ventilazione, il livello di illuminazione, di umidità e la percezione termica, fabbisogno energetico a partire dai vari impianti considerati, siano essi di cogenerazione, a base di fonti rinnovabili o a biomassa, carico termico e sua previsione per i sistemi HVAC, comfort abitativo, visivo e qualità dell'aria, effetti di illuminazione e di ombreggiamento. La maggior parte dei software sono in grado di segnalare anche eventuali criticità e la loro origine all'interno del report conclusivo.

2.1.2 I principali software di simulazione energetica

A titolo esemplificativo, vengono citati alcuni esponenti rappresentativi della categoria di software adibiti alla simulazione energetica:

- Energy Plus
- ESP-r (Energy Simulation Software)
- IDA ICE (IDA Indoor Climate Energy)
- IES VE (Integrated Enviromental Solutions – Virtual Enviroment)
- TRNSYS
- CitySim
- Urban Building Energy
- SimStadt

Energy Plus è tra i software di simulazione energetica più conosciuti. Permette di lavorare su diversi moduli e valutare i carichi termici e i fabbisogni di acqua ed energia nell'edificio; la preparazione, come già accennato, consiste in una prima fase di costruzione dell'edificio, pur se il software non fornisce un'interfaccia che mostri l'edificio completo, e in una seconda ed ultima fase di introduzione dei dati. ESP-r è un software matematico pensato per supportare progetti di edilizia nella fase di costruzione. Il funzionamento si basa sull'integrazione in successivi time step di equazioni complesse che tengano in considerazione allo stesso tempo la geometria, i materiali, la dissipazione del calore, e tutti gli altri elementi che influenzano la performance dell'edificio. Similmente al caso di Energy Plus, vengono integrati i dati sulle condizioni operative e sugli impianti da applicare. I tempi di simulazione

possono richiedere da pochi minuti a un'ora, in base alla complessità. Nel complesso, perciò, presenta le principali criticità che contraddistinguono l'intera categoria di software di simulazione energetica: le tempistiche proibitive, la difficoltà di utilizzo e il lungo tempo medio di training dell'utente. Presenta però i vantaggi tipici dei software basati su equazioni rispetto a quelli che utilizzano un linguaggio di programmazione imperativo: la capacità di risolvere problemi matematici particolarmente complessi.

Anche il software IDA ICE si basa su un sistema modulare, che viene descritto tramite equazioni simboliche. E' in grado di fornire un ambiente 3D per la modellazione dell'edificio. Rispetto ai precedenti, presenta una maggiore facilità di utilizzo. Altri punti di forza sono la presenza di un'interfaccia utente ESBO (Early Stage Building Optimization) che permette di analizzare diverse alternative inserendo un numero minimo di input e il vasto arsenale di componenti legati al mondo dell'energia rinnovabile. In aggiunta vanta una notevole flessibilità, poiché le librerie sono open source, scritti in Neutral Model Format, scriptabili con Common LISP, e quindi le equazioni del modello possono essere continuamente modificate e integrate. I tempi di esecuzione si rivelano sempre problematici, nonostante il livello di affidabilità garantito.

IES VE permette una definizione più dettagliata per il design dell'edificio. La simulazione termica si ottiene grazie all'integrazione con il tool ApacheSim, con Macro FLO per la ventilazione naturale e con HVAC Apache per le analisi sull'illuminazione e l'ombreggiatura. Il risultato completo può poi essere esportato.

TRNSYS, prodotto commerciale di proprietà dell'università del Wisconsin, concentra l'attenzione specialmente sull'impianto energetico, permettendo all'utente di dettagliarlo tramite l'interfaccia TRNBuild con elementi che vanno dalla semplice pompa di calore fino ad ottenere una visualizzazione ad alto livello di interi impianti multi-zone, prendendo in considerazione qualsiasi tipologia di componente, includendo anche pannelli solari e sistemi fotovoltaici. Le prestazioni computazionali sono sbalorditive, rientrando a volte nel range di 0.1 secondi. Gode a sua volta dei vantaggi derivati dall'architettura modulare, ad esempio la successiva aggiunta di modelli matematici e il miglioramento continuo, e si integra facilmente con altri strumenti, ad esempio Matlab ed Excel. Benché sia considerato uno dei software più completi e performanti, presenta come grosso limite l'impossibilità di integrarsi con AutoCAD.

Non tutti i software adottano un metodo di risoluzione completo delle equazioni che descrivono i modelli rappresentati; nei casi, infatti, di software che simulano il comportamento energetico di gruppi di edifici, se non di intere città, a causa della crescente complessità è necessario ricorrere a una soluzione dinamica di tipo semplificato oppure appoggiandosi ad assunzioni, come nei metodi steady-state. Ne sono esempi CitySim, SimStadt e Urban Building Energy.

2.1.3 Conclusioni

I software presentati sono considerati fra i più completi, poiché tengono conto di un gran numero di variabili, ma proprio per questo richiedono un notevole livello di expertise, oltre a rivelarsi computazionalmente pesanti a livello di tempi.

A seconda delle necessità dell'utente, è però possibile individuare il software più adatto. Per evidenziare in modo più comprensibile le differenze tra i software menzionati, le tabelle 2.1, 2.2, 2.3, 2.4, 2.5 e 2.6 presentano un confronto riassuntivo delle caratteristiche di ognuno. I software sono analizzati e valutati sotto diversi aspetti: sulla base della tipologia di soluzione fornita, dell'intervallo di tempo considerato per il calcolo, del livello di dettaglio reso possibile dalla descrizione geometrica, dell'attenzione dedicata al sistema elettrico e ai sistemi HVAC, dell'inclusione dei sistemi da risorse rinnovabili.

Tabella 2.1: Confronto tra i principali software in termini di tipologia di soluzione [Fonte Joana Sousa, Energy Simulation Software for Buildings: Review and Comparison][8]

TIPOLOGIA DI SOLUZIONE					
Feature	Energy Plus	ESP-r	IDA ICE	IES VE	TRNSYS
Permette la simulazione di sistemi, soluzioni, carichi	X	X	X	X	X
Opera una soluzione iterativa di sistemi non lineari	X	X	X	X	X

Tabella 2.2: Confronto tra i principali software in termini di durata dei tempi di calcolo [Fonte Joana Sousa, Energy Simulation Software for Buildings: Review and Comparison][8]

DURATA DEI TEMPI DI CALCOLO					
Feature	Energy Plus	ESP-r	IDA ICE	IES VE	TRNSYS
Utilizza intervalli di tempo variabili per zona per interazione con i sistemi HVAC	X	X			
Permette la selezione simultanea di diversi edifici da parte dell'utente		X	X	X	X
Ci sono variabili dinamiche per la soluzione di transitori	X	X	X		

Tabella 2.3: Confronto tra i principali software in termini di tipologia di soluzione in termini di completezza nei sistemi di energia rinnovabile [Fonte Joana Sousa, Energy Simulation Software for Buildings: Review and Comparison][8]

COMPLETEZZA NEI SISTEMI DI ENERGIA RINNOVABILE					
Feature	Energy Plus	ESP-r	IDA ICE	IES VE	TRNSYS
Include impianti ad energia solare	X	X		X	X
Include i muri Trombe Wall ad alta assorbività	X	X	X	X	X
Include i pannelli fotovoltaici	X	X		X	X
Include sistemi ad idrogeno per lo storage di energia		X			X
Include impianti ad energia dal vento		X			X

Tabella 2.4: Confronto tra i principali software in termini di completezza nei sistemi elettrici ed equipment [Fonte Joana Sousa, Energy Simulation Software for Buildings: Review and Comparison][8]

COMPLETEZZA NEI SISTEMI ELETTRICI ED EQUIPMENT					
Feature	Energy Plus	ESP-r	IDA ICE	IES VE	TRNSYS
Consente di produrre elettricità da fonti rinnovabili	X	X			X
Distribuisce e gestisce i carichi di elettricità	X	X			X
Include i generatori di elettricità	X				X
Include le connessioni alla rete	X	X			X

Tabella 2.5: Confronto tra i principali software in termini di completezza nei sistemi HVAC [Fonte Joana Sousa, Energy Simulation Software for Buildings: Review and Comparison][8]

COMPLETEZZA NEI SISTEMI HVAC					
Feature	Energy Plus	ESP-r	IDA ICE	IES VE	TRNSYS
Descrive in modo completo il sistema HVAC	X	X	X	X	X
Propone possibili configurazioni di sistemi HVAC	X	X	X	X	X
Calcola le frequenze di ricambio d'aria	X	X	X	X	X
Considera il sistema di distribuzione, parte del sistema elettrico	X	X	X	X	X
Analizza l'andamento di anidride carbonica			X	X	X
Calcola la distribuzione dell'aria per ciascuna area	X	X	X	X	X
Calcola le unità di aria immessa per ciascuna zona	X	X	X	X	X
Calcola le unità di equipment	X	X		X	X

Tabella 2.6: Confronto tra i principali software in termini di completezza della descrizione geometrica [Fonte Joana Sousa, Energy Simulation Software for Buildings: Review and Comparison][8]

COMPLETEZZA DELLA DESCRIZIONE GEOMETRICA					
Feature	Energy Plus	ESP ⁺ r	IDA ICE	IES VE	TRNSYS
Dettaglia muri, tetti e pavimenti	X	X	X	X	X
Dettaglia finestre, porte, lucernari, rivestimenti esterni	X	X	X	X	X
Permette la visualizzazione di poligoni con molte facce	X	X	X	X	
Consente l'importazione da programmi CAD	X	X	X	X	X
Esporta la geometria degli edifici per programmi CAD	X	X	X		
Importa o esporta i modelli di simulazione	X	X	X	X	
Calcola il punto di equilibrio termico	X	X	X	X	X
Calcola l'assorbimento o emissione di umidità da parte dei materiali di costruzione	X		X	X	X
Calcola la massa termica interna	X	X	X	X	X
Calcola il comfort termico percepito dagli occupanti	X	X	X	X	X
Effettua un'analisi solare	X				X
Effettua un'analisi dell'isolamento ottenuto	X	X	X	X	X
Permette uno studio approfondito della finestratura	X	X	X	X	X
Calcola i parametri generici dell'edificio	X	X		X	X
Calcola la temperatura di superficie per ogni zona	X	X	X	X	X
Calcola i flussi d'aria attraverso le finestre	X	X		X	X
Analizza le superfici di contatto	X	X	X	X	X
Calcola il trasferimento di calore dal suolo	X	X	X	X	X
Identifica le variabili termofisiche			X		
Identifica i livelli di luce artificiale e di luce naturale	X	X	X	X	
Analizza le infiltrazioni per ciascuna zona	X	X	X	X	X
Calcola automaticamente i coefficienti di pressione del vento				X	
Calcola la ventilazione naturale	X	X	X		X
Calcola sia la ventilazione naturale che quella artificiale				X	X
Consente il controllo dell'apertura delle finestre per la ventilazione naturale	X	X	X		X
Calcola le perdite d'aria per ciascuna zona	X	X	X		X

Si nota che sono molti i punti in comune, come già accennato, in primis per quanto riguarda la tipologia della soluzione e la metodologia di calcolo. Risulta evidente la completezza di TRNSYS, unico software a tenere conto di tutti gli aspetti, senza escludere né i sistemi elettrici né i sistemi ad energia rinnovabile, e allo stesso tempo senza trascurare la geometria dell'edificio e descrivendo nel modo più esauriente il contributo dei sistemi HVAC. TRNSYS offre però una minore customizzazione per gli intervalli di calcolo. Il livello di dettaglio geometrico è all'incirca uniforme, in particolare per IES VE; pari è anche l'attenzione dedicata ai contributi dei sistemi HVAC. Le differenze principali emergono nella presa in considerazione del sistema elettrico, assente in IDA ICE e IES VE, e dei sistemi a fonti rinnovabili, mancante in IDA ICE e poco dettagliato per IES VE e Energy Plus. Come già sottolineato, infine, le prestazioni differiscono per quanto riguarda la connessione con altri programmi e software: sotto questo punto di vista, il più penalizzato è TRNSYS, come anticipato.

2.2 Modelli

Una classificazione proveniente da 2001 ASHRAE Handbook—Fundamentals risalente al 2001[9] suggerisce una suddivisione in modelli forward e modelli inversi. I primi, di solito, iniziano con una descrizione fisica dell'edificio, riguardo ai materiali da costruzione, alla geometria, alla localizzazione geografica, alla tipologia di impianti, e rientrano nella descrizione fatta nella sezione precedente. Invece, i modelli inversi sono derivati dal comportamento empirico dell'edificio.

Similmente, i modelli in grado di caratterizzare il comportamento termico degli edifici vengono in altre istanze raggruppati secondo due tipi di classificazioni: in base all'interpretabilità, da cui vengono delineati tre principali gruppi che portano il nome di modelli a scatola bianca, grigia o nera, e in funzione della complessità. I modelli a scatola bianca si basano sulla conoscenza della fisica del sistema e su equazioni di bilanciamento termico, ricavate spesso attraverso i software di simulazione finora descritti. Questo tipo di modelli sono di solito computazionalmente complessi, richiedono un gran numero di parametri estremamente dettagliati in input e possono peccare in accuracy poiché spesso necessitano di appoggiarsi ad assunzioni non consistenti con la situazione contingente. La loro complessità, infatti, dipende principalmente dal livello di precisione richiesto dei fenomeni fisici associati al sistema da descrivere: spaziano da modelli statici a dinamici, possono optare per assunzioni di linearità o non linearità, possono offrire un'interpretazione differenziale, continua o non continua. Nel caso si ipotizzi uno scenario stazionario, o quasi stazionario, si calcolano gli scambi su periodi di tempo lunghi (anche mesi o stagioni) e gli effetti dinamici vengono presi in considerazione sottoforma di fattori di utilizzo empirici o basandosi su dati rilevati in edifici adiacenti. Se invece ci si

pone l'obiettivo di considerare una costante di tempo molto bassa, nell'ordine delle ore, e così includere l'effetto di tutti gli elementi dinamici, la variabile in output dipende dal tempo e il modello viene caratterizzato come un modello dinamico. La linearità del modello, invece, specifica il tipo di dipendenza di tale variabile dal tempo, mentre l'approccio differenziale specifica se l'espressione si presenta nella forma di equazione differenziale. Per la risoluzione delle equazioni di conduzione del calore si ricorre a metodi come quello delle differenze finite, oppure a metodi analitici quali il metodo delle funzioni di trasferimento, il metodo del fattore della risposta in frequenza e il metodo della matrice delle ammittanze. Di conseguenza, la performance dei modelli a scatola bianca è influenzata dal tipo di calcolo effettuato e porta con sé un certo margine d'errore, associato alle variabili randomiche che, diversamente da quelle dotate di un significato fisico, non sono rappresentate dai parametri inclusi nelle equazioni: esempi di questi effetti trascurati sono l'apertura delle finestre oppure il tasso di ventilazione naturale. Nonostante, però, le metodologie numeriche o analitiche prescelte e le assunzioni semplificative in grado di aggirare la notevole complessità e determinare la soluzione, sono modelli accomunati dalla caratteristica di essere completamente interpretabili.

Alternativamente, si può optare per modelli a scatola nera: si tratta di modelli empirici con parametri significativi a livello fisico, dove, contrariamente ai modelli a scatola bianca, il funzionamento si basa sull'individuazione delle relazioni tra le variabili in input e in output, indipendentemente dai fenomeni fisici del sistema studiato o dalle variabili randomiche, che d'altro canto rappresentano uno dei principali elementi di disturbo per i modelli white box. Sono appunto definiti black-box proprio perché propongono una soluzione senza alcun riferimento specifico alle equazioni utilizzate per modellare i fenomeni fisici. Nel caso dei modelli black-box, infatti, i parametri vengono individuati tramite un aggiustamento automatico, una sorta di calibrazione del modello, metodologia che costituisce la principale ragione dei vantaggi sui modelli interpretabili. D'altra parte, però, non sono in grado di tenere in considerazione i principi fondamentali della fisica, al punto che spesso gli output forniti sono inconsistenti con la realtà fisica, specialmente quando il dataset di training è di ridotte dimensioni. Come i modelli a scatola bianca, anche i modelli black-box possono essere classificati sulla base della staticità, linearità o differenzialità.

Una soluzione intermedia è rappresentata dai modelli a scatola grigia, dove vengono utilizzati dati sperimentali di input e di output e allo stesso tempo viene inclusa una conoscenza a priori del sistema da analizzare. I parametri di questi modelli hanno un significato fisico e mantengono anche un contatto con il mondo empirico. Per concludere, certamente le soluzioni a scatola bianca presentano alcuni vantaggi, come la possibilità di fornire una soluzione in grado di generalizzare e la capacità di svincolarsi dalla qualità del data set utilizzato per il training o dalla bontà dell'algoritmo utilizzato, a fronte però di costi computazionali notevolmente

superiori e talvolta, come detto, di una mancata aderenza alla realtà, in quanto manca totalmente l'aspetto empirico. L'approccio più opportuno da utilizzare deve essere selezionato sulla base dello specifico caso: se si è in possesso di una sufficiente conoscenza riguardo la trasmissione e l'immagazzinamento del calore, e dei corrispondenti parametri dotati di un significato fisico, è conveniente preferire questo tipo di soluzioni, che si rivelano in grado di descrivere al meglio tutti i fenomeni fisici del caso e di predire il consumo energetico in modo efficace. D'altro canto, queste soluzioni sono le uniche utilizzabili quando non c'è disponibilità di dati, come nel caso di edifici non ancora esistenti. I modelli a scatola bianca, inoltre, sono particolarmente utili nella fase di comprensione iniziale dei fondamentali fisici del sistema. Invece, se i fenomeni fisici che intercorrono all'interno dell'edificio sono troppo complessi da descrivere tramite i principi fondamentali della fisica, ma possono essere osservati o misurati, i modelli black-box risultano i più appropriati. Infine, se i fenomeni fisici che si verificano all'interno dell'edificio sono sia direttamente osservabili e allo stesso tempo hanno un significato fisico, i modelli grey-box si rivelano la scelta migliore. Sono soluzioni particolarmente fruibili anche nel caso in cui si intenda identificare i parametri che conducono agli errori più significativi nella predizione.

Di seguito, nelle tabelle 2.7, 2.8 e 2.9 sono stati evidenziati i punti di forza e di debolezza rispettivamente delle tre tipologie di modelli (white, grey e black-box) sfruttando una rappresentazione tabulare.

Tabella 2.7: Vantaggi e svantaggi dei modelli white box

MODELLI WHITE BOX	
VANTAGGI	SVANTAGGI
<ul style="list-style-type: none"> • Sono gli unici in grado di prevedere il comportamento di edifici nella fase di progettazione 	<ul style="list-style-type: none"> • Richiedono un gran numero di parametri in input: il processo di raccolta dei dati è lungo, costoso e non sempre consentito dal numero di sensori normalmente presenti
<ul style="list-style-type: none"> • Rimangono validi anche nel caso di variazioni nelle strategie di controllo dell'edificio 	<ul style="list-style-type: none"> • Richiedono costi computazionali altissimi
<ul style="list-style-type: none"> • Propongono soluzioni in grado di generalizzare il comportamento di tutti gli edifici 	<ul style="list-style-type: none"> • A volte non dimostrano aderenza alla realtà, poiché non sono inclusa alcuna evidenza sperimentale
<ul style="list-style-type: none"> • Il risultato non dipende dalla qualità del data set scelto 	<ul style="list-style-type: none"> • Portano con sé un certo margine d'errore, associato alle variabili randomiche
<ul style="list-style-type: none"> • Il risultato non dipende dall'algoritmo scelto 	
<ul style="list-style-type: none"> • I parametri possiedono un significato fisico, quindi si tratta di una soluzione interpretabile 	

Tabella 2.8: Vantaggi e svantaggi dei modelli grey box

MODELLI GREY BOX	
VANTAGGI	SVANTAGGI
<ul style="list-style-type: none"> • Richiedono meno dati di training rispetto ai modelli black box, quindi l'intervallo di tempo per la raccolta di dati è inferiore 	<ul style="list-style-type: none"> • I tempi di esecuzione non sono all'altezza di quelli dei modelli a scatola nera
<ul style="list-style-type: none"> • Richiedono meno parametri termici e architettonici in input rispetto ai modelli white box, quindi sono necessari meno sensori e c'è un minor costo di raccolta 	<ul style="list-style-type: none"> • Richiedono la presenza di un dataset su cui effettuare il training, anche se di dimensioni più ridotte rispetto ai modelli black-box
<ul style="list-style-type: none"> • Riassume i benefici dei due mondi e spesso mostra le performance migliori 	<ul style="list-style-type: none"> • Rimangono non adeguati agli edifici in fase di progettazione

Tabella 2.9: Vantaggi e svantaggi dei modelli black box

MODELLI BLACK BOX	
VANTAGGI	SVANTAGGI
<ul style="list-style-type: none"> • Riducono i costi computazionali 	<ul style="list-style-type: none"> • Non sempre tengono conto di tutti i fenomeni fisici (ad esempio oscillazioni dinamiche ad alta frequenza)
<ul style="list-style-type: none"> • Semplificano le casistiche dove i fenomeni fisici che intercorrono nell'edificio sono particolarmente complessi 	<ul style="list-style-type: none"> • Sono necessari molti dati e che includano tutti gli scenari, perciò include un lungo tempo e parecchi costi, specialmente in termini di quantità di dati: sono "data hungry"
<ul style="list-style-type: none"> • Eliminano gli errori dovuti alle variabili randomiche 	<ul style="list-style-type: none"> • Non sono adeguati per edifici non ancora esistenti poiché non esistono dati sperimentali
<ul style="list-style-type: none"> • Effettuano una calibrazione automatica dei parametri 	<ul style="list-style-type: none"> • Perdono efficacia nel caso in cui si decidesse di cambiare le strategie di controllo dell'edificio
<ul style="list-style-type: none"> • Riducono l'expertise necessaria per l'utilizzo 	<ul style="list-style-type: none"> • La bontà del risultato dipende dalla qualità dei dati in ingresso
	<ul style="list-style-type: none"> • Si può incorrere in overfitting, quindi dove sono in grado di modellare il comportamento di uno specifico edificio e manca la capacità di generalizzare
	<ul style="list-style-type: none"> • Con un dataset di ridotte dimensioni, potrebbero manifestare una non ridotta aderenza alla realtà
	<ul style="list-style-type: none"> • Manca del tutto la possibilità di interpretare la struttura del modello

La letteratura è particolarmente ricca di proposte di modelli con finalità di modellazione energetica, trattandosi di un tema molto attuale e urgente, come è già stato rimarcato nel primo capitolo. Vengono di seguito illustrati solo alcuni dei principali modelli presenti in letteratura, sia per quanto riguarda l'ambito black-box che l'ambito grey-box.

2.2.1 Modelli Grey Box

All'interno della seguente sottosezione, viene fornita una panoramica su alcuni dei modelli grey box più noti in letteratura, raggruppati in due macrofamiglie: i modelli basati sui circuiti termici e i modelli basati sulle reti neurali.

Modelli basati sui circuiti termici

In generale, la risoluzione dei modelli viene effettuata tramite tre categorie di metodologie, secondo Kampf:

- Le soluzioni esplicite, come il metodo delle differenze finite
- I metodi di semplificazione, come:
 - I circuiti equivalenti
 - Il metodo delle ammittanze
- Le tecniche di riduzione dell'ordine del modello

La necessità di semplificare i modelli diventa imperativo nel caso di simulatori come CitySim, SimStadt e Urban Building Energy che, come già anticipato, riguardano sistemi estremamente complessi. Essi si appoggiano, se non a modelli che si limitano alle condizioni stazionarie, a modelli dinamici semplificati, tra cui figurano i modelli a rete termica. La particolarità di questi ultimi è che il sistema di equazioni che descrive le condizioni termiche in un edificio si ottiene effettuando un parallelismo tra la corrente elettrica e lo scambio termico, dove l'equazione del bilancio termico diventa equivalente alla conservazione della corrente elettrica per ciascun nodo. Un edificio può essere così rappresentato da un modello semplificato di tipo RC (Resistance Capacitance), dove le masse termiche vengono rappresentate da capacitori, le masse conduttive, invece, da resistenze, i diversi strati di materiali da nodi e i flussi di calore dalla corrente. Il numero di capacitori presenti nella rete termica quantifica la complessità del modello, in quanto essi rappresentano le variabili di stato nell'equazione: un modello rappresentato da una rete termica con un capacitore è un modello di primo ordine, uno che include due capacitori è invece di secondo ordine, e così via. In conclusione, gli edifici possono essere rappresentati da un circuito con un nodo e una singola zona, con due nodi e una

singola zona, oppure da circuiti RC multi-zona e con multipli nodi: questo dipende dall'ammontare delle informazioni a disposizione per descrivere l'edificio, rendendo la sua rappresentazione via via più complessa.

I parametri vengono considerati come invarianti rispetto al tempo, per questo motivo sono modelli noti anche con il nome di modelli lumped-parameter. Dopo aver semplificato in questa veste tutti gli elementi multistrato, dall'unione di essi si ricava una rappresentazione semplificata dell'intera struttura, dove la trasmissione del calore è considerata in un'ottica monodimensionale.

Tali parametri devono venire poi determinati direttamente dalle caratteristiche termo-fisiche di materiali e in base alla geometria descritta. In caso ciò non fosse possibile, è allora necessario identificarli da dati sperimentali oppure basandosi su un modello di riferimento. Le diverse assunzioni e i diversi strumenti di cui ci si avvale per giungere alla soluzione sono le discriminanti tra i diversi modelli proposti.

L'introduzione del capostipite di questi modelli è stata opera di Beuken ed è la versione generica con n capacitori. In seguito, Rouvel lo semplificò descrivendo ogni elemento utilizzando un modello di primo o secondo ordine e quindi generalizzando l'intero edificio, composto da n elementi, con un modello di almeno n capacitori. Laret è stato l'artefice di un semplice modello che permetteva di riassumere ogni elemento della struttura con un circuito equivalente con un solo capacitore e due resistenze. In alcuni casi, vengono identificate due diverse costanti di tempo, una per la massa d'aria e l'altra per la struttura complessiva, un approccio introdotto per la prima volta da Lorenz e Masy. La superiorità del modello di secondo ordine è stata ribadita soprattutto dagli studi di Gouda, che evidenziarono che il modello di secondo ordine fosse un ottimo compromesso fra la complessità e l'accuracy della risposta. Svariati sono stati poi i metodi utilizzati per l'identificazione dei parametri: un esempio di un metodo numerico è stato quello di riduzione dell'ordine del modello, sfruttato da Gouda per identificare il modello più adatto a descrivere l'elemento complesso, e quello delle differenze finite, applicato da Antonopoulos e Koronaki ad un modello del primo ordine. Un altro modello in grado di operare una forte semplificazione, ma tenendo in considerazione le caratteristiche dell'edificio, è quello di Nielsen, che presenta due soli nodi. Un'ulteriore innovazione proposta da Rouvel e Zimmermann identifica due gruppi di elementi in base al loro comportamento termico, quelli di natura adiabatica e quelli di natura non adiabatica. Si tratta di un modello con una soluzione analitica con due costanti di tempo separate e simili. La letteratura è in continuo arricchimento di nuove proposte, fra le più innovative quella proveniente da Rodriguez che prevede una mobilità della capacità a seconda delle condizioni. Alcuni fra essi fanno riferimento a dati sperimentali e riescono a migliorare così la propria accuracy grazie alla possibilità di includere fenomeni non lineari, specialmente convettivi e radiativi; d'altro canto, perdere contatto con la fisica dell'edificio causa una perdita di robustezza del modello, per cui i tentativi si

concentrano nel raggiungere un adeguato trade-off.

Di seguito viene proposta una breve descrizione di alcuni dei principali modelli proposti in letteratura.

Modelli proposti come standard internazionali ISO 13790 e VDI 6007-1

[11] La proposta riguarda una coppia di modelli di tipo RC, perciò dinamici, dove si assume che la temperatura di un corpo solido sia una funzione del solo tempo, formulando così l'assunzione di uniformità della temperatura, e che la resistenza alla conduzione del calore attraverso i solidi sia trascurabile rispetto alla resistenza al trasferimento del calore fra un solido e un fluido.

Gli scenari considerati sono stati sia una stanza sia un appartamento, collocati in zone climatiche che spaziano da Palermo, a Venezia, a Vienna e ad Helsinki, ipotizzando poi due tipologie di edifici, light e heavy, privi o meno di insulazione, in modo da testare la validità del modello nelle condizioni più disparate. I dati si riferivano a due intervalli di tempo di eguale durata, collocati però l'uno in periodo di raffrescamento, l'altro in periodo di riscaldamento; alternativamente, si è assunto uno spegnimento degli impianti.

La prima rete termica è un modello di primo ordine, costituito da 5 resistenze e 1 solo capacitore. La procedura di costruzione del circuito termico prevede che ogni elemento dell'edificio sia rappresentato attraverso 5 nodi, in cui uno simboleggia la superficie esterna, un altro la superficie interna e i restanti sono catalogati come nodi interni. Invece, ogni elemento trasparente è rappresentato da due soli nodi, uno che simboleggia la superficie esterna e un altro che simboleggia la superficie interna. Viene infine aggiunto un ulteriore nodo che rappresenta la temperatura dell'aria interna. Per ogni elemento si identifica un'equazione di bilancio energetico per ogni nodo e per il nodo interno, e poi si risolve il sistema di equazioni per determinare la temperatura interna oppure il fabbisogno energetico per il raffrescamento o raffreddamento. Il termine lumped parameter indica che a partire da un circuito equivalente esteso si raggiunge una formulazione dove il numero di capacità e il numero di resistori è fissato a priori: in questo modo i tempi computazionali possono essere ridotti in modo sensibile. Nel circuito equivalente, i generatori di tensione rappresentano un differenziale di temperatura che causano un flusso di calore, così come una differenza di potenziale genererebbe un flusso di corrente elettrica. Le resistenze elettriche riflettono le trasmittanze dei materiali. La trasmittanza dell'elemento trasparente si colloca tra due nodi (θ_s e θ_e , rispettivamente la temperatura della superficie interna e la temperatura dell'aria esterna). La trasmittanza dei componenti opachi, invece, è suddivisa tra $H_{tr,em}$ e $H_{tr,ms}$, che introducono il nodo interno a temperatura θ_m . Un altro elemento di conduzione del calore è rappresentato dal coefficiente di ventilazione H_{ve} , che opera tra la temperatura dell'aria interna θ_b e la temperatura dell'aria ventilata θ_{sup} . Il componente capacitore modella la massa termica dell'aria interna, in grado di

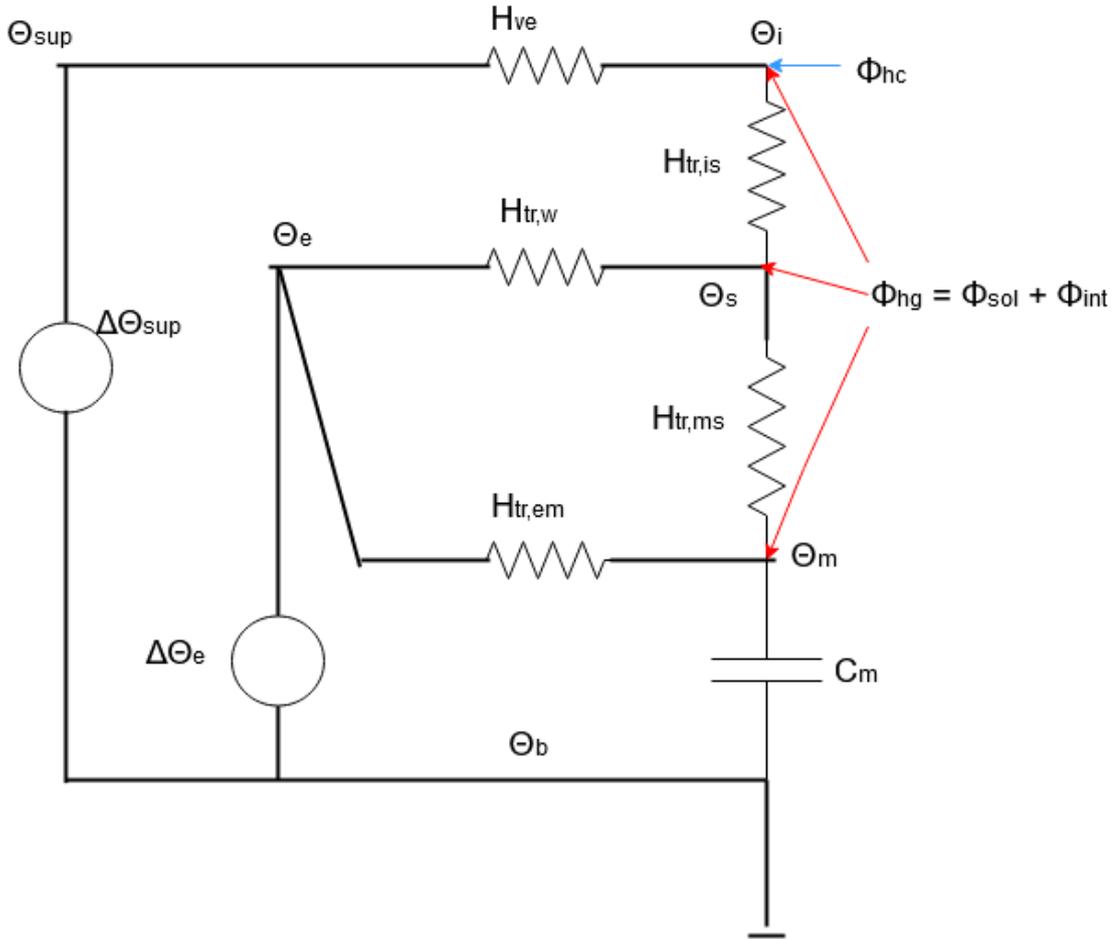


Figura 2.5: Rappresentazione del circuito termico nel modello ISO 13790

immagazzinare il calore, ma non di trasmetterlo egualmente bene come gli elementi solidi, il cui comportamento è invece rappresentato da resistenze. I flussi energetici positivi riguardano gli apporti interni, derivati dall'equipment funzionante e che dissipa energia e dagli occupanti che emanano calore.

Gli apporti solari sono caratterizzate secondo le equazioni 2.1 e 2.2.

$$\phi_{sol} = F_{so} I_{sol} (a_s R_{se} U_{op} A_{op}) - F_r \phi_r \quad (2.1)$$

$$\phi_r = R_{se} U_{op} A_{op} \alpha_{rad} \Delta\theta_{er} \quad (2.2)$$

All'interno delle equazioni 2.1 e 2.2 U_{op} è la trasmittanza dei componenti opachi, A_{op} è la loro area di estensione, α_s il coefficiente di assorbività, R_{se} la resistenza al calore superficiale, I_{sol} l'irradianza solare dell'istante considerato, F_r il fattore di

forma fra edificio e cielo e che raggiunge il valore di 0,5 in caso di verticalità del muro. All'apporto va sottratta una quota derivata dalla presenza di ostacoli che causano ombreggiatura, Φ_r , all'interno della cui formulazione α_{rad} è il coefficiente di scambio termico radiativo e ΔT_{er} è la differenza fra la temperatura dell'aria esterna e la temperatura apparente del cielo. Gli apporti interni sono invece quantificati come da equazione 2.3, dove A_{fl} è il flusso d'aria, ipotizzato costante.

$$\phi_{int} = 5,294A_{fl} - 0,01557A_{fl}^2 \quad (2.3)$$

L'equazione al singolo nodo è genericamente la seguente:

$$H_0 (\theta_{0,t} - \theta_{1,t}) + H_1 (\theta_{2,t} - \theta_{1,t}) + \phi_{1,t} = C_1 \left(\theta_{1,t} - \frac{\theta_{1,t-\Delta t}}{\Delta t} \right) \quad (2.4)$$

La risoluzione di un numero di equazioni, speculari alla 2.4, pari al numero dei nodi conduce alla soluzione, ossia all'identificazione del parametro in output richiesto. Il modello può essere reso più completo includendo un secondo capacitore, ed effettuando una distinzione fra la componente adiabatica ($C_{m,AW}$) e la componente non adiabatica ($C_{m,IW}$). Questa maggiore complessità permette di calcolare con più precisione la risposta termica ad alte frequenze. Una rappresentazione è disponibile in Figura 2.6. Gli elementi resistivi includono la resistenza termica causata dalla ventilazione (H_{ve}) che, dunque, è posizionato in mezzo al nodo della temperatura dell'aria interna (θ_b) e quella dell'aria ventilata (θ_{sup}). Un ulteriore miglioramento rispetto al modello 5RIC è l'introduzione delle componenti radiative e convettive, sia nella forma adiabatica che non adiabatica. Lo scambio di natura convettiva avviene fra l'aria interna e la superficie esterna ed interna dei muri, mentre il flusso radiativo ha luogo fra le due superfici. Nel complesso, la quantificazione della trasmissione del calore radiativa e convettiva è modellata tramite la forma equivalente di connessione a stella ($H_{a,IW}$, $H_{a,AW}$, $H_{a,i}$). D'altro canto, la componente conduttiva, già contemplata nel precedente modello, è rappresentata dalle trasmittanze $H_{m,IW}$, $H_{m,AW}$. La componente conduttiva dell'ultimo strato esterno viene identificata sottraendo alla trasmittanza totale la trasmittanza dovuta alla radiazione e la trasmittanza dovuta alla convezione, ottenuta effettuando il parallelo delle trasmittanze convettive sia degli elementi adiabatici che non adiabatici, come si può osservare nell'equazione 2.5.

$$R_{Rest;AW} = R_{ges;AW} - R_{1;AW} - \frac{1}{\left(1/R_{\alpha;conv;AW} + 1/R_{\alpha;conv;AW/IW}\right)} \quad (2.5)$$

La temperatura esterna include il contributo proveniente sia dal terreno e dal cielo, che quello dovuto all'energia solare assorbita dai muri, come si osserva nell'equazione 2.6.

$$\theta_{e;eq} = \theta_e + \Delta\theta_{e;eq;lw} + \Delta\theta_{e;eq;sw} \quad (2.6)$$

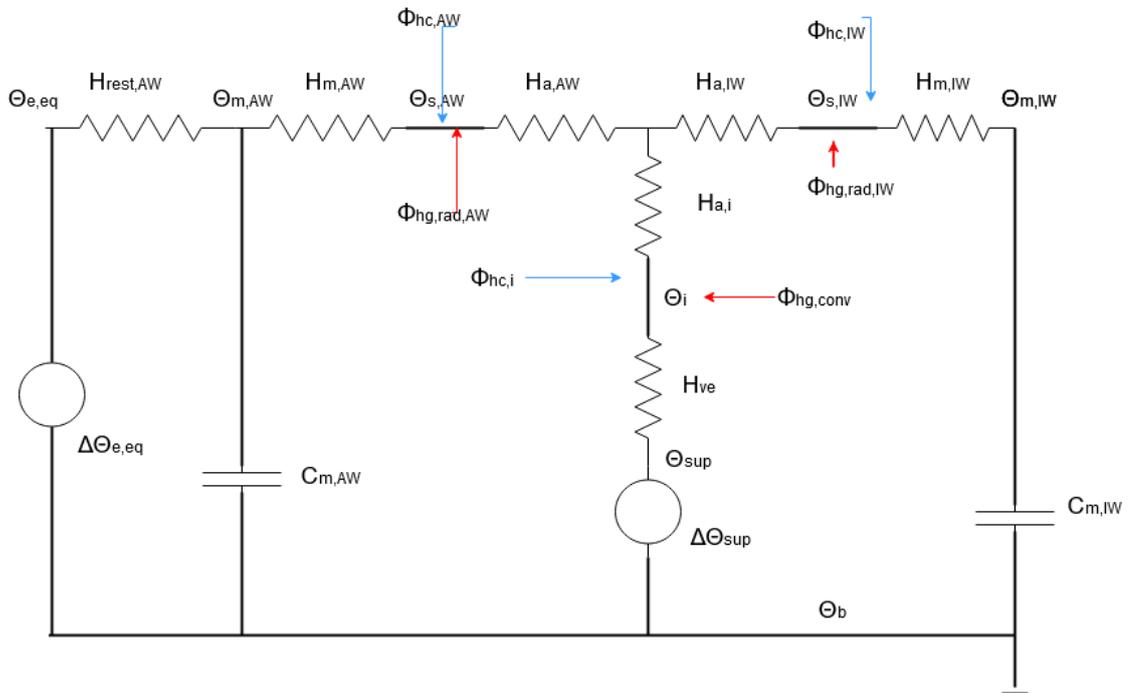


Figura 2.6: Rappresentazione del circuito termico nel modello VDI 6007-1

Benchè entrambi i modelli, confrontati con previsioni di riferimento ottenute grazie al software TRNYSIS, si rivelino affidabili nel caso delle analisi aggregate di consumi energetici sia per lo scenario di riscaldamento che per quello di raffreddamento, le performance del modello di secondo ordine sono superiori rispetto a quelle del modello di primo ordine quando si utilizza una costante di tempo dell'ordine delle ore, come anticipato, grazie alla distinzione fra elementi adiabatici e non: questo modello si dimostra particolarmente adeguato, perciò, con simili costanti di tempo e nelle simulazione di singole zone termiche, ipotesi di base per la composizione dei circuiti equivalenti. In questo caso, la riduzione dell'errore relativo (RMSE/media) rispetto al modello di primo ordine è evidente soprattutto per la stima del fabbisogno energetico richiesto dal riscaldamento, che viene sistematicamente sottostimato dal modello 5R1C. Per questo motivo, il modello di primo ordine viene consigliato nel caso di orizzonti di tempo estesi, quindi in condizioni di quasi stazionarietà.

Fraisse et Al. [12] Si tratta del primo modello in grado di fornire una soluzione analitica: questo tipo di soluzioni, a partire dal circuito equivalente completo, sono in grado di individuare un set di equazioni algebriche in grado di fornire un'adeguata approssimazione. Esso consente di rappresentare un elemento multistrato tramite

un modello di secondo o quarto ordine, dando vita a tre possibili alternative: un modello con un solo resistore e due capacitori (1R2C), uno con tre resistori e due capacitori (3R2C), uno con tre resistori e quattro capacitori (3R4C), rappresentati in figura 2.7. Essi sono in grado di includere anche i fenomeni di convezione e di radiazione tramite onde lunghe. I parametri di resistenza e capacità vengono identificati a partire dalle matrici di trasmissione dei materiali componenti: la matrice di trasmissione complessiva del modello ne è infatti il prodotto e il suo determinante deve essere unitario. L'estrema semplificazione del modello 1R2C prevede che la conduttività del muro multistrato sia rappresentata da un solo parametro, che quindi include anche le componenti superficiali. In essa, vi è il solo contributo della prima costante di tempo, non viene in alcun modo presa in considerazione una possibile inerzia né interna né esterna, perciò questo risulta in una sovrastima della temperatura interna quando vi è un aumento della temperatura esterna, e in una sottostima della temperatura interna quando vi è un aumento della temperatura interna, in quanto gli scambi di calore avvengono in modo molto più rapido. Questo modello si rivela affidabile solo con costanti di tempo superiori a circa 28 ore. D'altro canto, il modello 3R4C migliora la versione 3R2C tramite il metodo del 5%: vengono aggiunti due elementi capacitivi che aggiungono il 5% della capacità globale già esistente, con l'obiettivo di prendere in considerazione uno strato superficiali sottile che manifesti un'inerzia aggiuntiva quando si considerano costanti di tempo di 10 minuti: senza questa puntualizzazione, infatti, il calore raggiungerebbe direttamente uno strato più interno, pur in tempi così brevi. Sia il modello 3R2C sia il modello 3R4C stimano la temperatura in modo coerente con il modello di riferimento (che include ben 100 nodi), almeno fino a che la costante di tempo non scende sotto l'intervallo di 2.8 ore. Tuttavia, il modello 3R2C dimostra uno svantaggio nella determinazione della temperatura nel caso di un input proveniente dall'interno, perdendo efficacia al di sotto del valore di 6 ore, mentre il modello alternativo mantiene le prestazioni della simulazione riguardante un input esterno.

Il difetto strutturale di questo modello rimane comunque la perdita di accuracy all'aumentare del numero di strati e della dissimilarità fra gli elementi multistrato rappresentati dai circuiti equivalenti e poi aggregati.

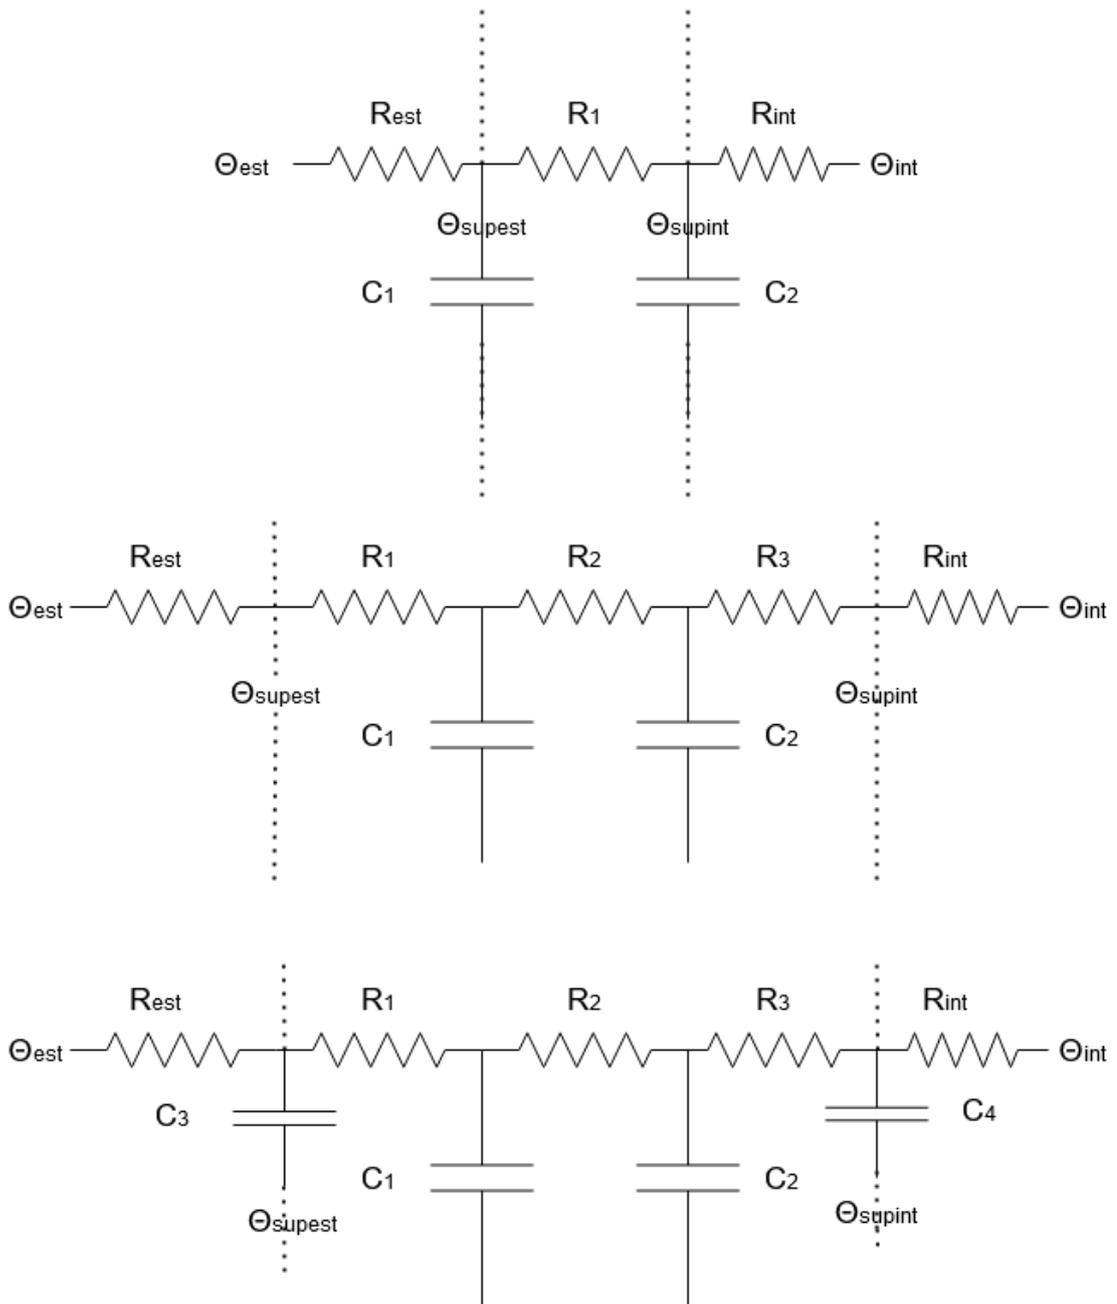


Figura 2.7: Rappresentazione dei circuiti termici equivalenti, con complessità 1R2C, 3R2C e 3R4C, secondo il modello di Fraisse

Ramallo-González et Al. [13] Questo modello prevede la creazione di un circuito equivalente Lumped-Parameter costituito da tre resistori e due capacitori. Si tratta di una proposta di tipo analitico che si pone l'obiettivo di migliorare la performance del modello di Fraisse anche con elementi dotati di molti strati. Ogni singolo strato viene considerato come un elemento indipendente, mentre i principali fattori di influenza vengono identificati come la temperatura esterna, applicata allo strato più esterno, e gli apporti interni, entrambi dipendenti dal tempo. La temperatura interna viene quindi calcolata come la somma di due modelli: uno che considera soltanto la temperatura dell'aria esterna, l'altro che considera soltanto come input gli apporti interni. Si tratta di un'assunzione, dunque, piuttosto forte, in quanto esclude qualunque forma di trasmissione di calore alternativa, ad esempio tramite radiazione o convezione.

L'elemento multistrato viene ricondotto a un modello di secondo ordine, dove lo strato esterno è in contatto soltanto con il nodo che rappresenta la temperatura esterna. I due contributi vengono idealmente rappresentati da due generatori sinusoidali collocati agli estremi del circuito. Poiché ogni serie di tempo può essere decomposta in un set di armoniche a frequenze differenti, è possibile identificare le frequenze dominante relative agli input del sistema. Un modello che si dimostra efficace nell'identificazione degli input viene ipotizzato come accurato anche nella realtà. Facendo riferimento al teorema di Shannon-Nyquist, che stabilisce che una funzione continua può essere totalmente descritta da una serie di tempo discreta solo se la funzione originale non ha armoniche maggiori della frequenza di metà della frequenza del campione della serie di tempo, si assume che le armoniche ad alte frequenze possano venire trascurate, cosicché sia possibile la rappresentazione della funzione continua tramite serie di tempo. Si individuano due frequenze che delimitano il range di frequenze rilevanti e le corrispondenti pulsazioni, secondo le equazioni 2.7, 2.8, 2.9 e 2.10.

$$f_{UB} = f_{SN} = \frac{1}{2T_s} = 0,5h^{-1} \quad (2.7)$$

$$\omega_{UB} = 2\pi f_{SN} = \pi rad/h \quad (2.8)$$

$$f_{LB} = \frac{1}{2\pi} \frac{1}{\left(\sum_0^n R_k \sum_0^n C_k\right)} \quad (2.9)$$

$$\omega_{LB} = 1 / \left(\sum_0^n R_k \sum_0^n C_k \right) \quad (2.10)$$

Ogni strato è poi caratterizzato da un valore di influenza, determinato secondo la formula 2.11.

$$Inf_k = \left(\int_{\omega_{LB}}^{\omega_{UB}} \left(\left| \left(\frac{1}{j\omega C_k} \right) + \left(\frac{R_k}{2} \right) + \sum_{j=k+1}^n R_j \right| \right) d\omega \right)^{-1} \quad (2.11)$$

Il massimo tra i valori di influenza corrisponde a quello dello strato definito dominante, che assegna il valore alla capacità C2. Vengono identificate le due costanti di tempo riferite allo strato interno ed esterno, presentate nelle equazioni 2.12 e 2.13, calcolando la sommatoria dallo strato interno verso lo strato dominante per la prima, e dallo strato esterno verso lo strato dominante per la seconda.

$$\tau_{is} = \sum_{j=1}^{dom-1} \left(C_j \left(\frac{R_j}{2} + \frac{R_{dom}}{2} + \sum_{k=j+1}^{dom-1} R_k \right) \right) \quad (2.12)$$

$$\tau_{os} = \sum_{j=1}^{dom-1} \left(C_j \left(\frac{R_j}{2} + \sum_{k=1}^{j-1} R_k \right) \right) \quad (2.13)$$

Vengono infine di conseguenza identificati i parametri del circuito equivalente, secondo le equazioni 2.14, 2.15, 2.16, 2.17, 2.18.

$$R_1 = \left(\frac{R'_T \tau_{os}}{\tau_{is} + \tau_{os}} \right) \quad (2.14)$$

$$R_2 = \left(\frac{R'_T \tau_{is}}{\tau_{is} + \tau_{os}} \right) \quad (2.15)$$

$$R_3 = 0,5R_{dom} + \sum_{i=dom+1}^n R_i \quad (2.16)$$

$$C_1 = \frac{\tau_{os}}{R_1} = \frac{\tau_{is}}{R_2} \quad (2.17)$$

$$C_2 = C_{dom} \quad (2.18)$$

Si tratta di un modello che dimostra che tenere in considerazione le condizioni operative dell'edificio è una strategia preferibile all'individuazione dei coefficienti di trasferimento, come è stato fatto nei modelli precedenti, soprattutto con edifici insulati e complessi, che stanno ormai assumendo un ruolo di primo piano.

Wang et Al. [14] All'interno di questo modello, i parametri del circuito equivalente vengono identificati utilizzando un algoritmo genetico, una tecnica di machine learning, appartenente al sottogruppo delle tecniche di reinforcement learning. L'applicazione dell'algoritmo è però successiva a una conoscenza anche se approssimativa dell'edificio, perciò non si può catalogare questo modello come un modello black-box.

Questo modello è in grado di rappresentare gli elementi multistrato come tetto e involucro esterno secondo un circuito equivalente 3R2C, mentre gli elementi multistrato interni verranno approssimati tramite modelli 2R2C, come riportato in figura 2.8. I valori dei parametri saranno determinati a partire da dati sperimentali, utilizzando l'algoritmo genetico. Il nodo centrale, che rappresenta la temperatura

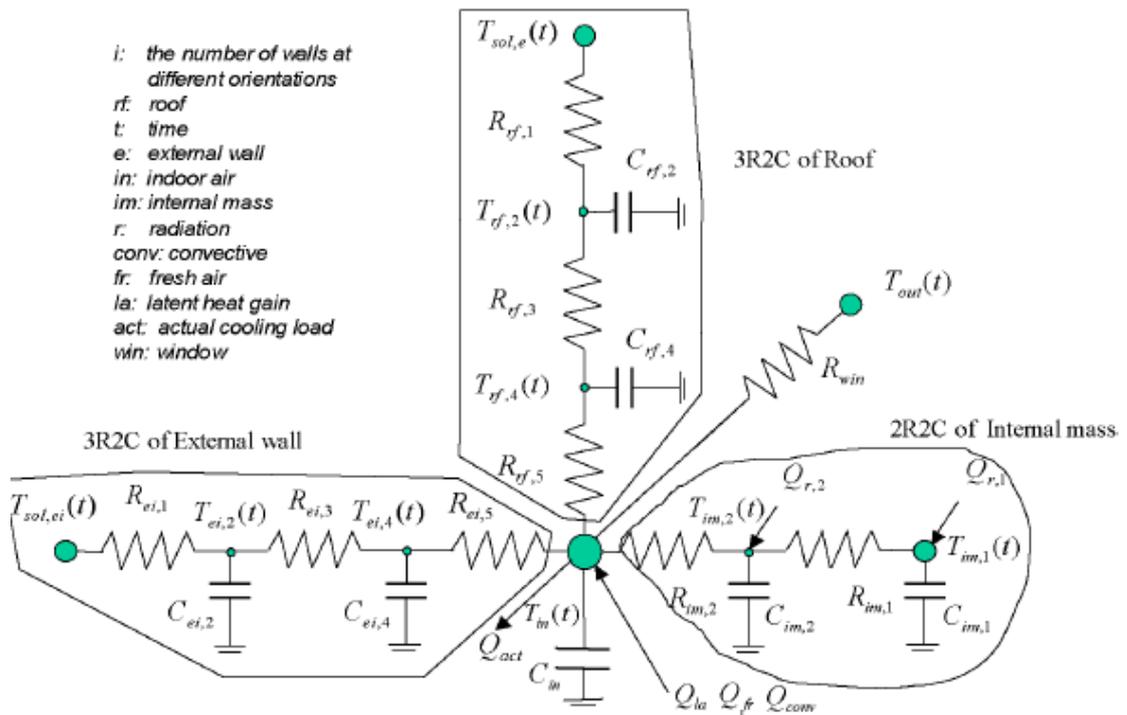


Figura 2.8: Rappresentazione del circuito equivalente per il modello basato sull'algoritmo genetico

dell'aria interna, assorbe il calore convettivo proveniente dagli occupanti, dalle luci e dal resto delle apparecchiature, il calore latente emesso dagli occupanti tramite respirazione e la componente, negativa o positiva, dovuta alle infiltrazioni e alla ventilazione. A partire dallo stesso nodo, è indicato anche il calore sottratto o fornito dall'impianto di riscaldamento/raffreddamento. Q_{r1} e Q_{r2} sono le componenti radiative proveniente sia dal sole, che dagli occupanti, che dalle luci, assorbite dalle strutture interne, mentre Q_{act} è il fabbisogno misurato.

Si effettuano i bilanciamenti ad ogni nodo eguagliando il calore entrante a quello immagazzinato all'interno del capacitore, come mostrato nelle equazioni 2.19, 2.20, 2.21, 2.22, 2.23, 2.24, 2.25.

$$C_{rf,2} \frac{dT_{rf,2}(t)}{dt} = \frac{T_{sol,rf}(t) - T_{rf,2}(t)}{R_{rf,1}} - \frac{T_{rf,2}(t) - T_{rf,4}(t)}{R_{rf,3}} \quad (2.19)$$

$$C_{rf,4} \frac{dT_{rf,4}(t)}{dt} = \frac{T_{rf,2}(t) - T_{rf,4}(t)}{R_{rf,3}} - \frac{T_{rf,4}(t) - T_m(t)}{R_{rf,5}} \quad (2.20)$$

$$C_{ei,2} \frac{dT_{ei,2}(t)}{dt} = \frac{T_{sol,ei}(t) - T_{ei,2}(t)}{R_{ei,1}} - \frac{T_{ei,2}(t) - T_{ei,4}(t)}{R_{ei,3}} \quad (2.21)$$

$$C_{ei,4} \frac{dT_{ei,4}(t)}{dt} = \frac{T_{ei,2}(t) - T_{ei,4}(t)}{R_{ei,3}} - \frac{T_{ei,4}(t) - T_{in}(t)}{R_{ei,5}} \quad (2.22)$$

$$C_{im,1} \frac{dT_{im,1}(t)}{dt} = Q_{r,1} - \frac{T_{im,1}(t) - T_{im,2}(t)}{R_{im,1}} \quad (2.23)$$

$$C_{im,1} \frac{dT_{im,1}(t)}{dt} = Q_{r,1} - \frac{T_{im,1}(t) - T_{im,2}(t)}{R_{im,1}} \quad (2.24)$$

$$C_{im,2} \frac{dT_{im,2}(t)}{dt} = Q_{r,2} + \frac{T_{im,1}(t) - T_{im,2}(t)}{R_{im,1}} - \frac{T_{im,2}(t) - T_{in}(t)}{R_{im,2}} \quad (2.25)$$

Il fabbisogno predetto è il risultato del bilanciamento al nodo centrale, considerando le resistenze a contatto con il nodo e le temperature del nodo ad esse adiacente, i contributi esogeni, sottraendo il quantitativo trattenuto dalla massa termica interna e aggiungendo anche la componente che penetra attraverso gli elementi trasparenti, rappresentati come elementi puramente resistivi (R_{win}) e a contatto con la temperatura dell'aria esterna (T_{out}) (equazione 2.26).

$$Q_{est} = \sum_{i=1}^n \left(\frac{T_{ei,4}(t) - T_{in}(t)}{R_{ei,5}} + \frac{T_{rf,4}(t) - T_{in}(t)}{R_{rf,5}} + \frac{T_{im,2}(t) - T_{in}(t)}{R_{im,2}} + \frac{T_{out}(t) - T_{in}(t)}{R_{win}} - C_{in} \frac{dT_{in}(t)}{dt} + Q_{conv} + Q_{fr} + Q_{la} \right) \quad (2.26)$$

La trasmissione del calore viene modellata in funzione di una variabile laplaciana (s), così da mettere in relazione le temperature delle superfici esterne ed interne e i flussi di calore interni ed esterni (equazione 2.7). La matrice di trasmissione deriva dal prodotto delle singole matrici di trasmissione, ed ognuna di esse descrive attraverso i parametri le caratteristiche trasmissive dell'elemento. Lo strato interno ed esterno possiedono una forma matriciale leggermente diversa perché la loro

capacità termica è definita trascurabile rispetto alla resistenza termica (equazione 2.28).

$$\begin{bmatrix} T_{in}(s) \\ q_{in}(s) \end{bmatrix} = M(s) \begin{bmatrix} T_{out}(s) \\ q_{out}(s) \end{bmatrix} = \begin{bmatrix} A(s) & B(s) \\ C(s) & D(s) \end{bmatrix} \begin{bmatrix} T_{out}(s) \\ q_{out}(s) \end{bmatrix} \quad (2.27)$$

$$M_i = \begin{bmatrix} 1 & -R_i \\ 0 & 1 \end{bmatrix} \quad (2.28)$$

Le funzioni di trasferimento riguardanti la conduzione del calore esterno, interno e trasversale della costruzione sono ottenuti tramite un rimaneggiamento dell'equazione e sono espresse nell'equazione 2.29.

$$\begin{bmatrix} q_{out}(s) \\ q_{in}(s) \end{bmatrix} = \begin{bmatrix} -G_X(s) & G_Y(s) \\ -G_Y(s) & G_Z(s) \end{bmatrix} \begin{bmatrix} T_{out}(s) \\ q_{out}(s) \end{bmatrix} \quad (2.29)$$

E' ora necessario ottenere i valori ottimali delle resistenze e capacità in modo che la fase e l'ampiezza della frequenza del modello corrispondano a quelli del trasferimento del calore attraverso il sistema reale. L'ottimizzazione dei parametri avviene identificando una funzione obiettivo (equazioni 2.30 e 2.31).

$$J_{3R2C}(R_1, R_5, C_4) = \sum_{n=1}^N \sum_{m=X,Y,Z} \left(W_m^{AM} \left| |G_m(j\omega_n)| - |G'_m(j\omega_n)| \right| + W_m^{PL} x \left| PL(G_m(j\omega_n)) - PL(G'_m(j\omega_n)) \right| \right) \quad (2.30)$$

$$J_{2R2C}(C_{im,1}, R_{im,1}, C_{im,2}, R_{im,2}) = \sqrt[2]{\frac{\sum_{k=1}^N (Q_{act,k} - Q_{est,k})^2}{N-1}} \quad (2.31)$$

G_m rappresenta la funzione di trasferimento con i parametri derivati dalla frequenza teorica, mentre G'_m è l'incognita da cui identificare i parametri del modello, ottenendoli tutti infine per sottrazione a partire dalla capacità e resistenza totali. L'algoritmo genetico inizializza i parametri in modo casuale, controlla se essi rispettano i vincoli, ossia che siano tutti maggiori di zero e che la loro somma sia inferiore alla resistenza e alla capacità totale, e in caso positivo prosegue con una selezione e crossover mutation iterativa fino al raggiungimento del numero di cicli previsto. L'iterazione viene bloccata solo se, al termine dei cicli previsti, la frequenza è divenuta quella richiesta dal problema di ottimizzazione, e il cui valore si calcola a partire dalla funzione obiettivo secondo le equazioni 2.32 e 2.33.

$$f_{3R2C}(R_1, R_5, C_4) = \frac{1}{J_{3R2C}(R_1, R_5, C_4)} \quad (2.32)$$

$$f_{2R2C}(C_{im,1}, R_{im,1}, C_{im,2}, R_{im,2}) = \frac{1}{J_{2R2C}(C_{im,1}R_{im,1}C_{im,2}R_{im,2})} \quad (2.33)$$

L'algoritmo viene quindi applicato indipendentemente per l'involucro e per la massa interna dell'edificio. La particolarità del modello è che i parametri vengono individuati in base alle caratteristiche fisiche solo per l'involucro esterno, mentre per la massa termica interna dell'edificio si fa riferimento ai dati storici. L'algoritmo genetico è uno strumento efficiente per l'ottimizzazione non lineare dei parametri, ed è in grado quindi di oltrepassare i limiti già manifestati in modelli precedenti che faticavano a tenere conto di effetti non lineari. Il contributo dei dati storici si manifesta in modo chiaro attraverso un aumento nell'accuracy; allo stesso tempo, il modello mantiene una notevole robustezza grazie all'inclusione anche della conoscenza della fisica dell'edificio grazie a cui vengono determinati alcuni parametri del modello semplificato.

Buonomano [15] DETECt è un modello di simulazione che è stato validato in base allo standard BESTEST, ed è un esempio di come i modelli dinamici semplificati siano in grado di costituire una solida base per software di simulazione delle prestazioni energetiche. Il modello si appoggia alle ipotesi semplificative che prevedono di considerare all'interno dell'edificio alcune zone, ben separate e indipendenti. Ogni elemento multistrato all'interno di ogni zona viene rappresentato tramite un circuito equivalente, dove ogni singolo strato è descritto da una porzione di circuito che comprende due resistori e un capacitore. A questi si aggiungono due nodi agli estremi, che modellano il comportamento sugli strati superficiali, e infine un nodo interno con la temperatura dell'aria interna (figura 2.9). Dal

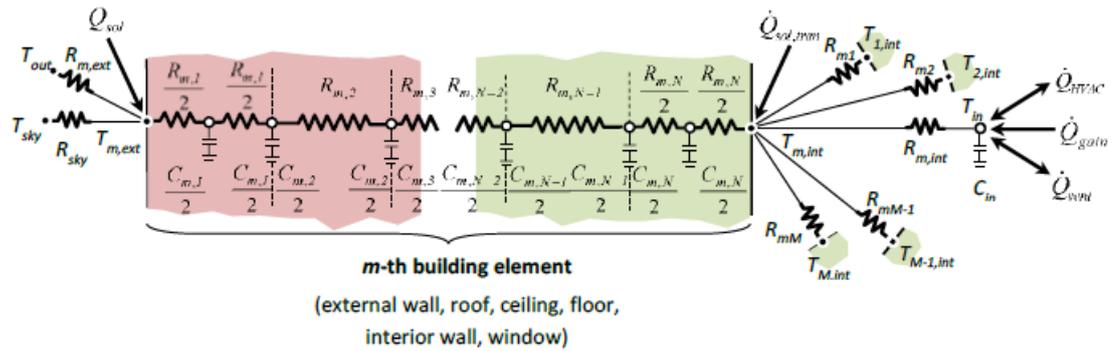


Figura 2.9: Rappresentazione del circuito equivalente per l'*m*-esimo elemento per il modello DETECt [15]

lato esterno, si osservano altri due nodi, uno che riporta la temperatura dell'aria esterna (T_{out}) e uno che riporta la temperatura apparente del cielo (T_{sky}). Essi

influenzano la temperatura della superficie esterna ($T_{m,ext}$) attraverso le relative resistenze. Il contributo solare (Q_{sol}) insiste anche su questo nodo. Sul nodo superficiale interno, ha influenza invece la componente solare trasmessa ($Q_{sol,tran}$), oltre che i contributi degli elementi confinanti, mediati dalle resistenze termiche di contatto. La temperatura dell'aria interna, invece, è influenzata direttamente dal carico termico proveniente dall'impianto, dalla ventilazione e dagli apporti interni. Il numero di nodi conclusivi risulta essere pari a:

$$num = z(m(n + 2) + 1) \quad (2.34)$$

All'interno dell'equazione 2.34 m è il numero di elementi, n di nodi e z è il numero di zone. Per un m -esimo elemento e un n -esimo nodo, vale l'equazione 2.35, tenendo conto che esistono nodi non capacitivi (i due nodi superficiali) dove il valore di capacità è pari a zero ed esiste il contributo radiativo (quindi solo in questi casi γ è diverso da 0). R_{cond} vale $R_{m,n/2}$ nel caso di contatto del nodo in esame con il nodo non capacitivo, $R_{m,n}$ altrimenti.

$$C_{m,n} \frac{dT_{m,n}}{dt} = \sum_{j=n-1}^{n+1} \frac{T_{m,j} - T_{m,n}}{R_{m,jn}} + \gamma \dot{Q}_{m,n}^{rad} \quad (2.35)$$

I contributi radiativi sono calcolati assumendo che lo strato esterno sia a contatto con la temperatura esterna, mentre quello interno sia a contatto con la temperatura interna e con tutti gli strati interni adiacenti (equazioni 2.36 e 2.37).

$$\dot{Q}_{m,0}^{rad} = [\epsilon_m^{ext} \sigma f (T_{sky}^4 - T_{m,1}^4) + \alpha_m^{ext} I_m^{ext}] A_m \quad (2.36)$$

$$\dot{Q}_{m,N+1}^{rad} = \left[\epsilon_m^{int} \sigma \sum_{i=1}^M G_{bm} (T_{i,N}^4 - T_{m,N}^4) + \alpha_m^{int} I_m^{int} \right] A_m \quad (2.37)$$

G_{bm} è un coefficiente della matrice di Gebhart che rappresenta la frazione della radiazione emessa dalla superficie dell'elemento m che viene assorbita dalle restanti appartenenti alla stessa zona. Il nodo interno è invece così descritto:

$$C_{in} \frac{dT_{in}}{dt} = \sum_{m=1}^M \frac{T_{m,N} - T_{in}}{R_{m,int}^{conv}} + \dot{Q}_{gain} + \dot{Q}_{vent} + \dot{Q}_{hc} \left[\epsilon_m^{int} \sigma \sum_{i=1}^M G_{bm} (T_{i,N}^4 - T_{m,N}^4) + \alpha_m^{int} I_m^{int} \right] A_m \quad (2.38)$$

Per quanto riguarda invece gli apporti interni, essi sono calcolati a partire dallo scheduling dell'utilizzo dell'edificio; il carico termico dovuto alla ventilazione è assunto proporzionale alla portata dell'aria ventilata, includendo anche le infiltrazioni, mentre il carico termico è calcolato sulla base della temperatura di set

point da mantenere e viene immesso nell'ambiente secondo un sistema di controllo proporzionale e integrativo. Si tratta di un modello che necessita di una conoscenza dell'edificio di partenza e richiede particolare cura anche nella determinazione di parametri come l'irradianza solare, calcolata a partire da una matrice che include le diverse riflessività e assorbività, dei materiali, i vari fattori di forma, le ombreggiature e gli angoli che individuano l'esatta posizione del sole. Si dimostra particolarmente utile nel caso di materiali in grado di cambiare la propria fase, permettendo così di far dipendere i parametri resistivi e capacitivi dal tempo, nel caso di ambienti completamente trasparenti o nel caso di obiettivi di controllo efficiente della luce artificiale grazie alla particolare attenzione dedicata ai fasci di luce solare, così come nei casi in cui si desidera approfondire l'interazione tra l'occupazione dell'edificio e il suo comportamento dinamico.

Braun et Al. [16] Si tratta di un modello inverso che utilizza una funzione di trasferimento i cui parametri vengono forzati a rispettare le condizioni fisiche del trasferimento di energia all'interno di una struttura, e inoltre viene anche effettuato un training. Se, dunque, i parametri iniziali vengono stimati in base a una conoscenza approssimativa dell'edificio in modo che soddisfino i vincoli, in seguito vengono perfezionati tramite un algoritmo di ricerca diretta, e infine ottimizzati utilizzando un algoritmo di regressione non lineare. La robustezza di questo modello consente di migliorare le performance del modello iniziale, che prevedeva solamente il training sulla funzione di trasferimento, che esprime il carico termico sensibile necessario al tempo k per mantenere gli interni alla temperatura di set point (equazione 2.39) e, di conseguenza, la temperatura interna (equazione 2.40).

$$\dot{Q}_{zs,k} = \sum_{i=0}^N (a_i T_{a,k-i} + b_i T_{z,k-i} + c_i \dot{Q}_{g,s,k-i} + d_i \dot{Q}_{sol,k-i}) + \sum_{i=1}^M e_i \dot{Q}_{zs,k-i} \quad (2.39)$$

$$T_{z,k} = \frac{1}{b_0} \left[\dot{Q}_{zs,k} - \sum_{i=1}^M e_i \dot{Q}_{zs,k-i} - \sum_{i=0}^N (a_i T_{a,k-i} + c_i \dot{Q}_{g,s,k-i} + d_i \dot{Q}_{sol,k-i}) + \sum_{i=1}^N b_i T_{z,k-i} \right] \quad (2.40)$$

Le dipendenze si trovano in funzione dei coefficienti della funzione di trasferimento e includono i contributi della temperatura ambiente e dell'intera zona z , la radiazione solare incidente sulla superficie esterna al tempo k e gli apporti interni sensibili al tempo k . L'ultimo termine all'interno dell'equazione 2.39 esprime il calore sensibile in funzione degli istanti di tempo precedenti a quello considerato. L'equazione 2.40 viene ottenuta a partire dalla prima grazie a rimaneggiamenti algebrici. Limitandosi

a questa procedura, non solo è necessario un vasto dataset, ma si riscontrano delle oscillazioni ad alta frequenza non presenti nei dati sperimentali. Con il fine di eliminarle, si descrivono gli elementi tramite un circuito equivalente (figura 2.10) i cui parametri iniziali vengono determinati tramite un algoritmo di regressione che minimizza gli errori rispetto a un modello completo risolto attraverso il metodo delle differenze finite e che allo stesso tempo deve rispettare il vincolo che la somma sia equivalente al valore reale, obiettivo raggiunto utilizzando un algoritmo di ricerca globale. La funzione di costo che guida la regressione è quella del RMSE (equazione 2.41), minimizzata tramite un algoritmo di Levenberg-Marquardt attenuando le disparità ad ogni istante di tempo tra il carico energetico previsto e quello effettivo risultante dal dataset di training (N è infatti il numero di elementi nel dataset di training).

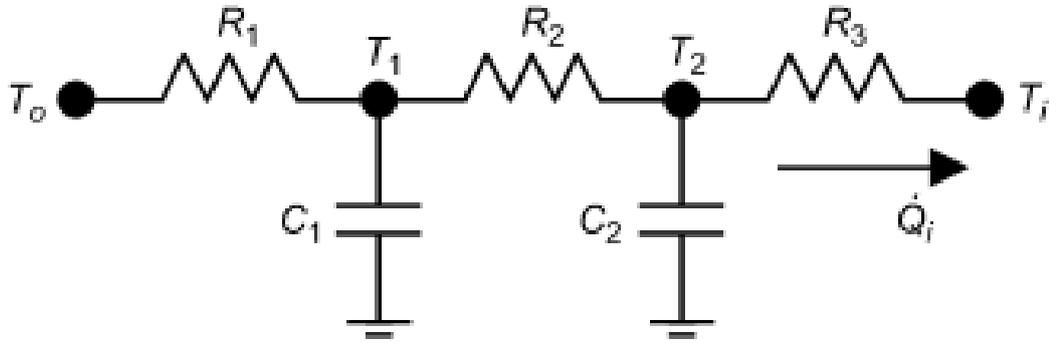


Figura 2.10: Rappresentazione parziale del circuito equivalente nel modello di Braun et Al. [16]

$$J = \sqrt{\frac{\sum_{k=1}^N (\dot{Q}_{i,m,k} - \dot{Q}_{i,d,k})^2}{N-1}} \quad (2.41)$$

Viene così identificata la funzione di trasferimento i cui coefficienti dipendono dai parametri ipotizzati. L'intera struttura viene composta ipotizzando cinque tipi diversi di elementi costituenti: muri esterni, tetto, pavimento, muri interni, finestre, tutti elementi rappresentati da circuiti equivalenti a due nodi, con l'eccezione delle finestre, approssimate tramite una pura resistenza (figura 2.11). Questa soluzione ibrida permette di ridimensionare il dataset di training, che dai 21 giorni iniziali raggiunge la durata di una settimana, nel caso in cui il dataset includa variazioni nella temperatura delle zone; in caso contrario, richiede fino a due settimane. Allo stesso tempo, si dimostra che le performance del modello di secondo ordine non vengono migliorate sensibilmente dal modello di terzo ordine, confermando ancora una volta l'adeguatezza di questo ordine.

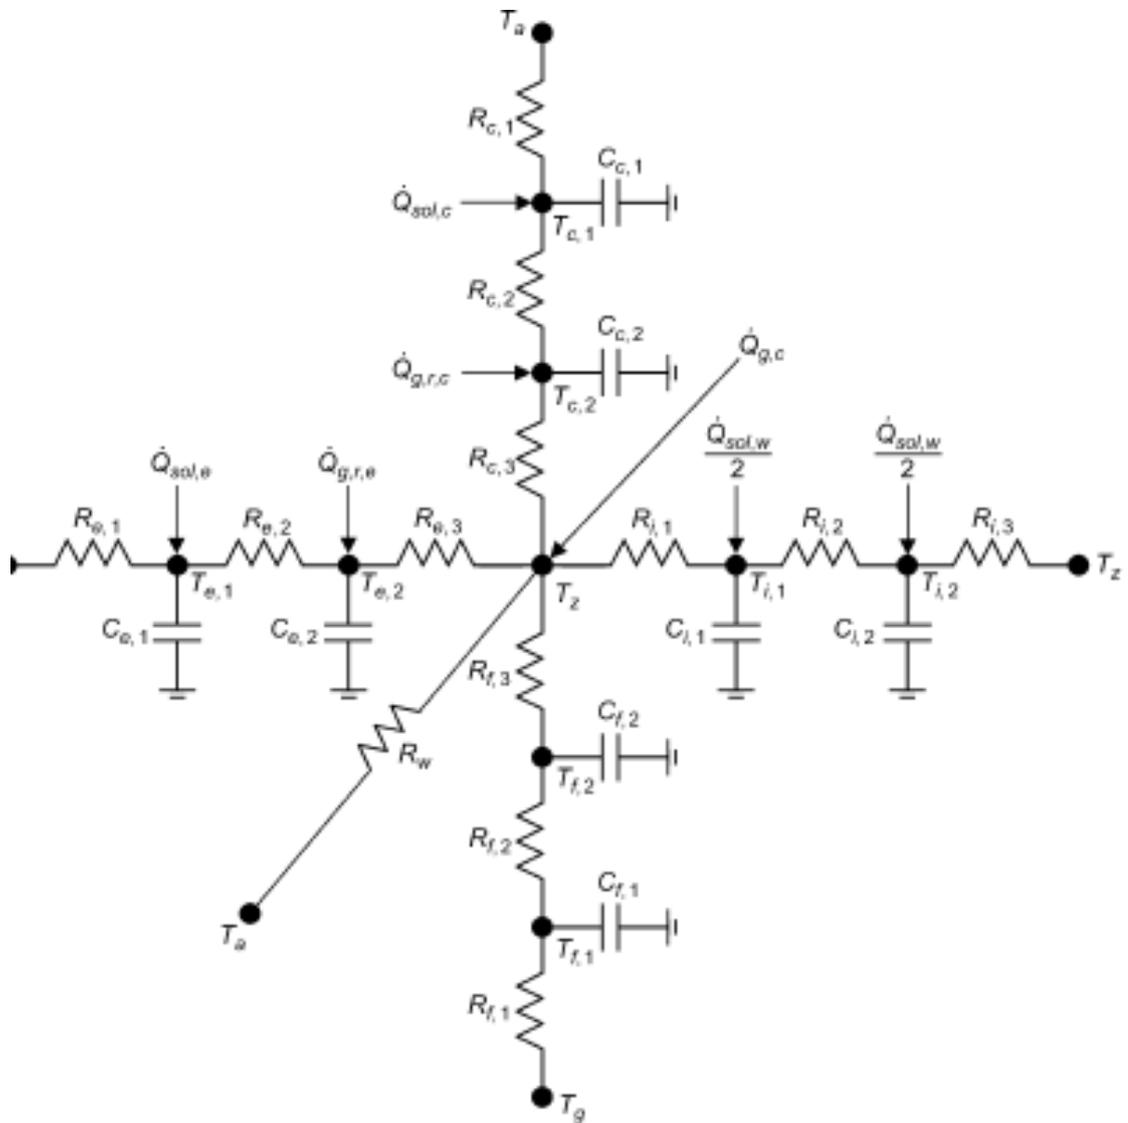


Figura 2.11: Rappresentazione del circuito equivalente globale nel modello di Braun et Al. [16]

Modelli basati sulle reti neurali

Gli ultimi sviluppi in letteratura prevedono l'integrazione di tecniche matematiche alla struttura delle reti neurali. La ricerca ha cominciato a muoversi in questo senso nel tentativo di oltrepassare la criticità dell'errore introdotto da ciascun layer e che si propaga sistematicamente. Un passo importante è stata l'implementazione da parte di Microsoft delle Residual Neural Network, che sono in grado di risolvere lo storico problema della scomparsa del gradiente che contribuisce all'aumento dell'errore. Il funzionamento prevede l'aggiunta all'output di ogni layer di un input residuale corrispondente all'output del layer precedente al contributo derivato dal processamento dello stesso input da parte della funzione di attivazione relativo al layer, come riportato nell'equazione 2.42. Se questa tipologia di reti ha introdotto il possibile sfruttamento delle tecniche di calcolo nell'ambito delle reti neurali, la formalizzazione è avvenuta poi con l'implementazione di modelli ibridi come Neural Ordinary Differentials Equations.

$$x(t + h) = x + F(x) \quad (2.42)$$

Reti neurali basate su equazioni differenziali ordinarie - Chen et Al. [17]

A partire dalla formula di identificazione dell'output per le Residual Neural Network (equazione 2.42) si intuisce che con una semplice moltiplicazione del generico fattore h alla funzione di attivazione si raggiunge la formula di Eulero, che modella una variabile in funzione della sua derivata (equazione 2.43).

$$x(t + h) = x(t) + hx(t)' \quad (2.43)$$

Sostituendo $F(x)$ a $x(t)'$ e considerando intervalli di tempo infinitesimi risulta evidente che le metodologie di risoluzione delle equazioni differenziali possono essere utilizzate per identificare sottoforma di una funzione continua definita da ciascun layer, e aggregati attraverso la tecnica di adjoint state, e non più attraverso singoli segmenti definiti da ciascun layer, la funzione motrice della serie di tempo. La dinamica continua di ogni layer nascosto viene parametrizzata tramite, quindi, un'equazione differenziale ordinaria (equazione 2.44), dove $h(t)$ è lo stato di riferimento, equazione che trova la sua risoluzione tramite black-box solvers, tra cui si citano diverse librerie dell'ambiente Julia, nate per combinare la risoluzione di equazioni differenziali con il mondo del Machine Learning.

$$\frac{dh(t)}{dt} = f(h(t), t, \theta) \quad (2.44)$$

Il metodo adjoint sensitivity consente di individuare la forma aggregata della funzione tramite un'integrazione per parti, mantenendo una dipendenza esplicita dalle variabili fisicamente più significative e modellandola perdita del gradiente

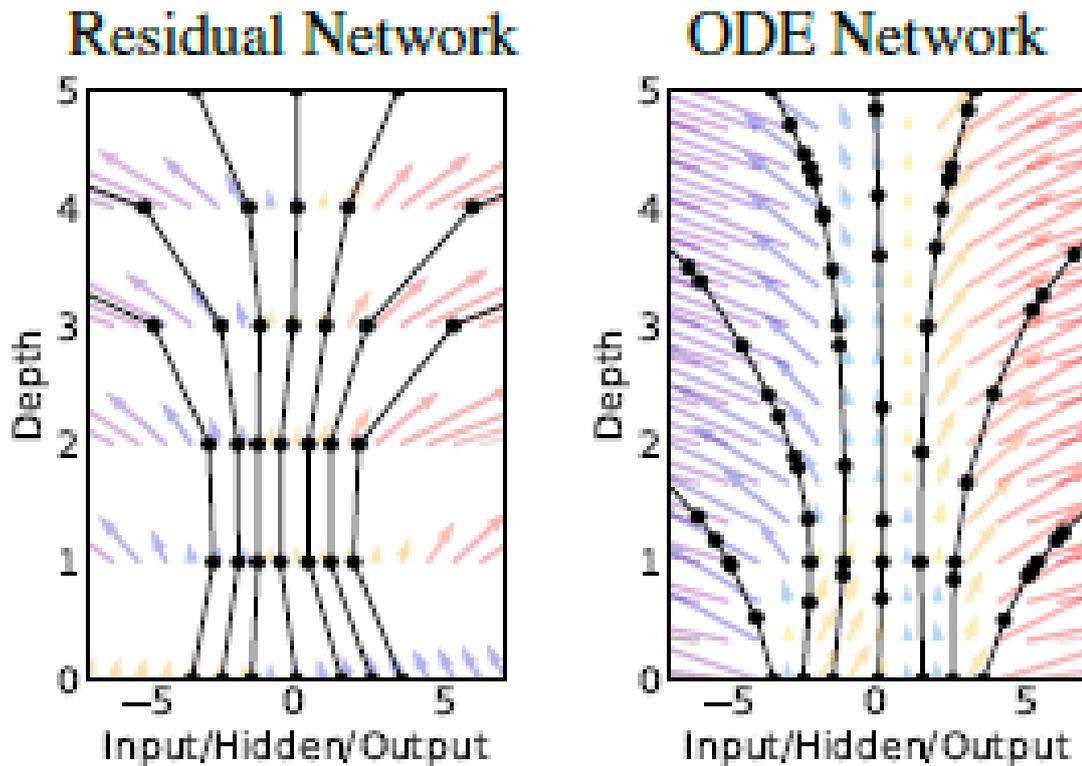


Figura 2.12: Comparazione fra reti neurali residuali e ODE: le prime definiscono una sequenza discreta di trasformazioni finite, le seconde, invece, passano dal discreto al continuo [17]

$dL/dz(t)$ sulla base degli output forniti dal risolutore (figura 2.13). Sono modelli particolarmente utili per quanto riguarda dati raccolti con campionamenti irregolari, perché sono in grado di individuare per ogni serie di tempo una traiettoria latente, determinata in base agli stati. Poiché la funzione, dipendente dallo stato citato, che esprime il gradiente è tempo-invariante, a partire da ogni stato è possibile definire univocamente la traiettoria. Il modello, definito Latent ODE, è stato confrontato tramite RMSE con modelli RNN, di comune utilizzo nella generazione di serie di tempo, ed ha ottenuto risultati migliori.

Questa tipologia di modelli sono denominati Neural Ordinary Differential Equations e si rivelano estremamente promettenti soprattutto per i risultati accurati ottenuti nella predizione delle serie di tempo. Inoltre, sono anche in grado di accorciare i tempi di training, di calcolare il gradiente con un costo costante di memoria e non mostrano necessità di discretizzare le osservazioni, poiché i dati vengono incorporati automaticamente, come non esiste nemmeno l'imperativo di normalizzare le variabili in input. Diversamente da altri modelli, non c'è necessità di definire la profondità

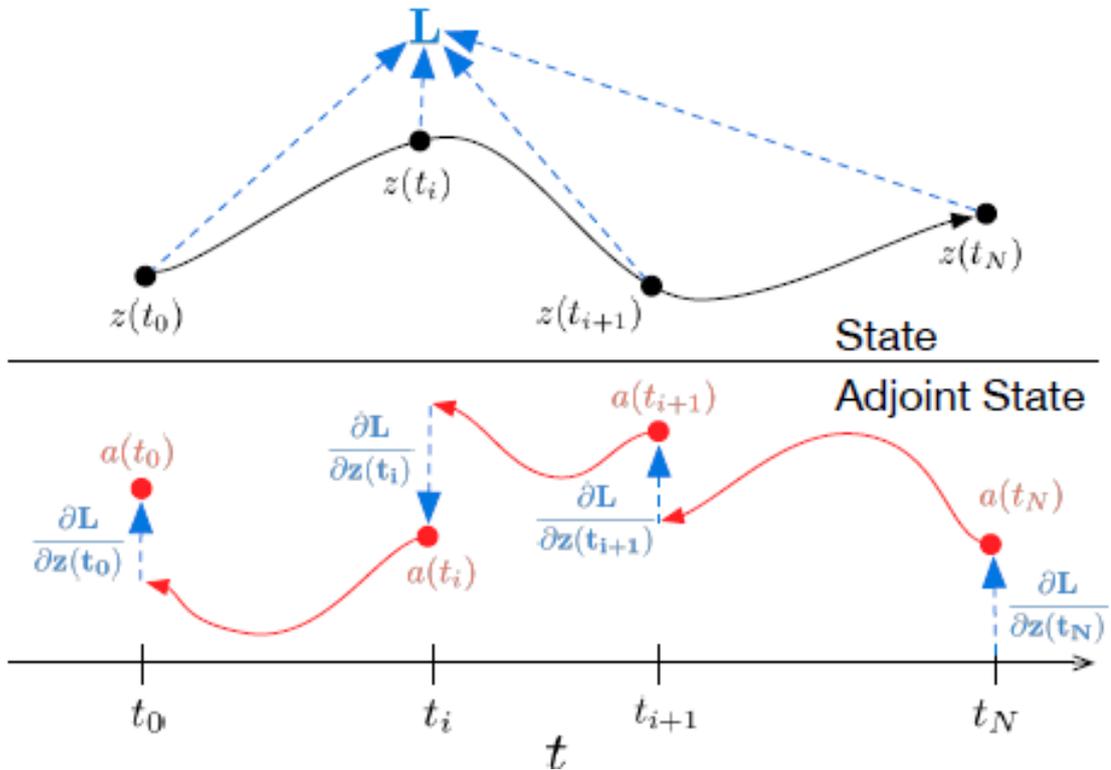


Figura 2.13: Rappresentazione del metodo adjoint sensitivity [17]

della rete, in quanto la determinazione del numero necessario di valutazioni dei layer nascosti è delegata al risolutore black-box, che è anche in grado di controllare e gestire al meglio l'errore di approssimazione, adattandolo all'accuracy richiesta. In conclusione, sono modelli ibridi che permettono di fruire di tutti i vantaggi legati generalmente a modelli gray-box, fra i quali non è da trascurare una migliore interpretabilità della struttura del modello, un requisito a volte imprescindibile.

Reti neurali physics-guided - Karpatne et Al. [18] L'esigenza di adattare i modelli black-box, conservandone gli innegabili punti di forza, rendendoli scientificamente consistenti con la realtà fisica, rendendoli più interpretabili, meno dipendenti dai dati a disposizione e più portati alla generalizzazione, si è tradotta nell'implementazione di una categoria di reti neurali physics-guided, più che data-driven: reti, cioè, che completando il loro percorso di apprendimento rispettando una funzione di perdita che enfatizza le relazioni fisiche fra le variabili. Si tratta, dunque, di modelli che si collocano in una posizione intermedia tra i modelli basati sui dati e i modelli legati alle teorie scientifiche, e in grado di ereditare i punti di forza di entrambi. Nel concreto, viene aggiunta alla funzione di perdita da minimizzare anche un

contributo che quantifica l'inconsistenza fisica: un aspetto che, dunque, l'algoritmo di ottimizzazione non può trascurare. Lo studio, nello specifico, ha previsto la creazione di dati in input grazie a un modello physics-based detto General Lake Model (GLM), in grado di modellare le dinamiche della temperatura all'interno di un lago. Successivamente, è stata definita la funzione di perdita, in particolare il termine legato all'inconsistenza fisica: sapendo che la pressione cresce con la profondità, si aggiunge una funzione che equivale al massimo termine fra 0 e la differenza di pressione fra il punto più in superficie e quello più in profondità per ogni coppia di punti presa in considerazione e se ne calcola la media dividendo il valore per il numero di coppie considerate, cosicché in caso di positività della funzione il termine d'errore complessivamente cresca in modo proporzionale. Il modello la cui funzione di perdita è stata così modificata è stata confrontato in termini di RMSE e della frazione di time-steps in cui il modello otteneva previsioni inconsistenti dal punto di vista fisico, con lo stesso GLM, con una rete neurale tradizionale e con una rete neurale che si limitava a ricevere in input i parametri physics-based ma senza mettere in atto la modifica della funzione. Il risultato mostra che il modello riesce a mantenere l'accuracy derivata dalla feature engineering ottenuta grazie al GLM e allo stesso tempo diminuisce l'inconsistenza fisica grazie alla modifica della funzione di perdita.

Modelli grey-box basati su Unscented Kalman Filter - Massano et Al. [19] Questa proposta prevede l'integrazione alla tecnica basata sulle reti termiche di un metodo detto Unscented Kalman Filter. La metodologia viene testata su due edifici, sempre ipotizzati come collocati a Torino, ma con due differenti rappresentazioni; entrambi i dati relativi ai due edifici sono stati forniti dal simulatore Energy Plus in assenza di dati autentici. Il primo edificio è stato rappresentato da una rete termica che include 5 zone, il secondo da una che ne include 17, visibili rispettivamente in figure 2.14 e 2.15. Il metodo Unscented Kalman Filter (UKF) trova la sua collocazione nella determinazione dei parametri della rete termica. Esso era già stato applicato in precedenza da Fux et al. su una rete semplice elementare (1R1C). Esso si basa sull'assunzione che una funzione con distribuzione probabilistica sia più facile da approssimare rispetto a una funzione arbitraria non lineare. La distribuzione viene approssimata tramite una gaussiana. In questo modo, una variabile randomica può essere approssimata tramite un set di equazioni, grazie a una trasformazione non lineare. L'innovazione riguarda in particolare la proposta di un filtro multiplo per il calcolo delle variabili, che utilizza un diverso set di equazioni a seconda della zona di riferimento, contrariamente al filtro singolo utilizzato di consueto, così da gestire al meglio la complessità. Inoltre, si è osservata anche la variazione delle performance in base alla presa in considerazione o meno del sistema HVAC e, nel caso positivo, se tali variabili fossero considerati come input o come disturbo. I test dimostrano che l'utilizzo del filtro multiplo permette

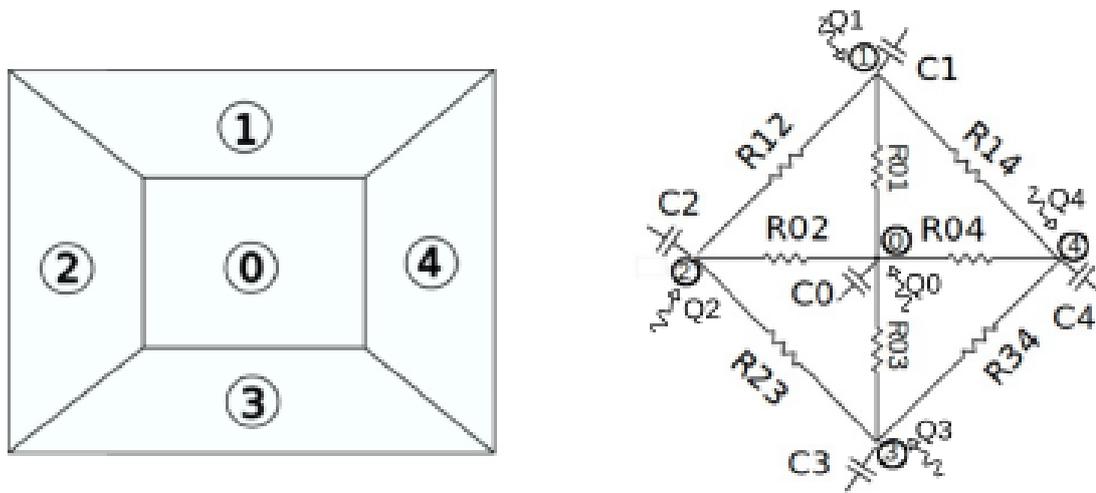


Figura 2.14: Rappresentazione del primo edificio con relativo circuito equivalente [19]

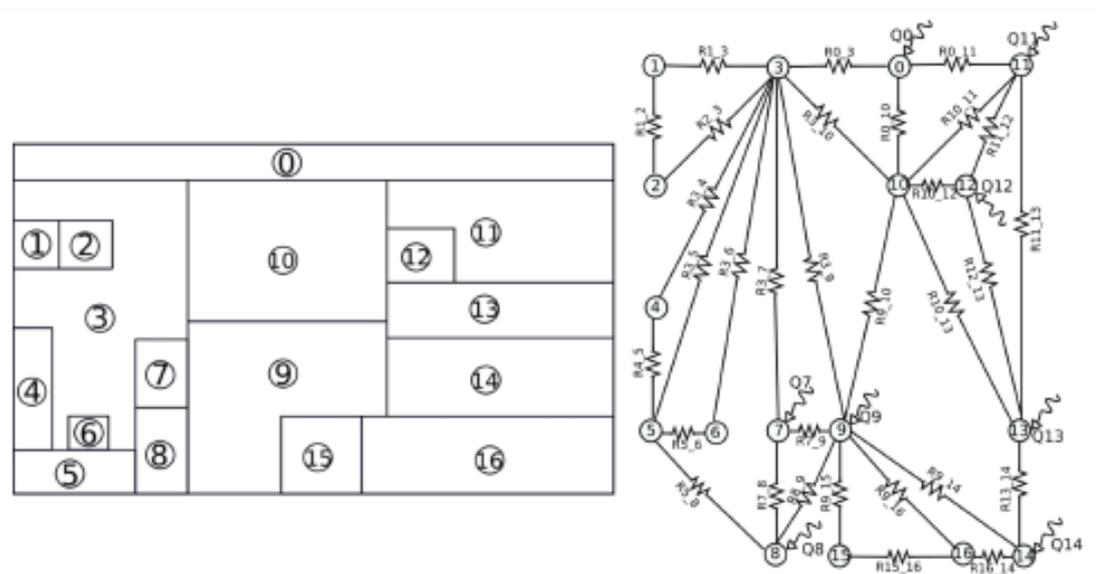


Figura 2.15: Rappresentazione del secondo edificio con relativo circuito equivalente [19]

di raggiungere buoni risultati, enfatizzati considerando il sistema HVAC come disturbo. D'altro canto, come atteso, la maggiore complessità nel modello a 17 zone penalizza visibilmente le performance, in qualsiasi casistica.

2.2.2 Modelli Black-Box

Principali tecniche di Machine Learning utilizzate in letteratura

La disciplina del Machine Learning è una disciplina complessa e in continua evoluzione. Sono diverse le tecniche che hanno finora trovato applicazione nell'ambito della predizione delle variabili energetiche all'interno degli edifici, così da fornire una panoramica il più possibile completa. Una posizione di primo piano è assunta dalle tecniche di regressione, che a differenza delle metodologie classificative sono in grado di prevedere il valore di variabili continue, non discrete. La regressione lineare, la tipologia più semplice, è stata utilizzata già nel corso degli anni 90. Altre tipologie di regressori che si trovano applicate a questo ambito in letteratura è Non negative Least Squares Regression. Si tratta di una versione dell'applicazione alla regressione del metodo dei minimi quadrati, con l'imposizione però che i coefficienti non possano essere negativi. Sempre tra gli approcci regressivi di ispirazione statistica, sono stati fatti dei tentativi tramite il modello di regressione lineare generalizzato: è una versione della regressione lineare più flessibile, che include anche variabili la cui distribuzione non è normale. Per questa ragione, questi modelli sono identificati da tre parametri: la famiglia, cioè il tipo di distribuzione relativa alla variabile di risposta, la specifica funzione lineare di predizione, e una funzione di collegamento che lega la media del valore atteso con il predittore. Esso non deve essere confuso con il modello regressivo lineare generale, che invece prevede semplicemente la compattazione di diversi modelli di regressione lineare sviluppati simultaneamente. E' possibile anche applicare l'approccio bayesiano, che permette di calcolare la media della distribuzione e la funzione di probabilità secondo il teorema di Bayes. Un'altra tecnica di regressione esplorata in questo campo è stata la regressione basata sui componenti indipendenti: è un approccio che deriva dall'analisi dei componenti indipendenti, un'alternativa alla più nota analisi dei componenti principali. L'assunzione su cui si basa il modello è che i componenti tra essi indipendenti siano in grado di descrivere meglio il fenomeno rispetto ai soli componenti principali, in quanto l'indipendenza tra variabili è una condizione più determinante rispetto alla semplice ortogonalità.

Sempre all'interno della categoria dei modelli lineari generalizzati, sono stati considerati anche i modelli generalizzati additivi, che si contraddistinguono perché la variabile di risposta dipende da predittori che sono dipendente in modo lineare da funzioni non necessariamente con una forma parametrica specificata; questo aspetto permette una maggiore flessibilità e permette di aderire con più precisione ai dati sperimentali, anche se con una perdita di interpretabilità a causa dell'impossibilità di delineare le funzioni sopracitate.

Una delle vie più percorse include i metodi di regressione penalizzata, che dal principio mantengono tutte le variabili predittive nel modello, ma vincolano la regressione riducendo i coefficienti a zero, così da identificare i predittori con il peso

maggiore nella determinazione della variabile prevista e mantenere solo questi ultimi nell'equazione finale. Tra essi, i più utilizzati prevedono tecniche di regolarizzazione come Ridge e Lasso, alternativi al classico stimatore basato sul metodo dei minimi quadrati. Lasso è l'acronimo di Least Absolute Shrinkage and Selection Operator e consiste nell'operare, come detto, una sorta di feature selection che possa ridurre la varianza proposta dal modello con una perdita accettabile di accuracy. Identifica lo stimatore osservando il metodo dei minimi quadrati, ma aggiungendo un contributo proporzionale alla semplice somma dei coefficienti assoluti e con un peso identificato dalla variabile λ , che nel caso di valore nullo riconduce l'equazione (2.45) a quella originaria. Alternativamente, la regolarizzazione Ridge basa la propria penalità sulla somma dei quadrati dei coefficienti assoluti (equazione 2.46).

$$\hat{\beta}_\lambda = \operatorname{argmin}_b \sum_{I=1}^n (y_i - x_i b)^2 + \lambda \sum_{k=1}^K |b_k| \quad (2.45)$$

$$\hat{\beta}_\lambda = \operatorname{argmin}_b \sum_{I=1}^n (y_i - x_i b)^2 + \lambda \sum_{k=1}^K b_k^2 \quad (2.46)$$

Tra le due, la tecnica di regolarizzazione Lasso è più interpretabile e risulta più adeguata nelle situazioni in cui il numero di predittori significativi, ossia con un alto valore dei coefficienti corrispondenti, è limitato; al contrario, la metodologia Ridge offre migliori prestazioni nei casi in cui la variabile di risposta è funzione di molti predittori, tutti con un peso all'incirca simile. Un metodo ibrido fra i due, in grado di cogliere i vantaggi di entrambi, è invece la regolarizzazione Elastic Net, che effettua una penalizzazione utilizzando entrambi i termini, come riportato nell'equazione 2.47.

$$\hat{\beta}_{enet} = \operatorname{argmin}_b \frac{\sum_{i=1}^n (y_i - x_i b)^2}{2n} + \lambda \left(\frac{1 - \alpha}{2} \sum_{k=1}^K b_k^2 + \alpha \sum_{k=1}^K |b_k| \right) \quad (2.47)$$

Un'alternativa alla regressione standard operata col metodo dei minimi quadrati è invece la regressione tramite minimi quadrati parziale (PLS), che risulta migliorativa, in caso di non regolarizzazione, quando la matrice dei predittori conta più variabili che osservazioni. Essa produce come output un modello lineare proiettando su un ulteriore spazio i valori delle variabili predette e di quelle osservate, identificando poi la direzione nello spazio originario dove quelle predette riescono a spiegare in massima parte la varianza delle osservate nello spazio generato ad hoc. Esistono anche versioni dei modelli di regressioni che consentono di tenere in conto anche gli effetti delle variabili in precedenti istanti di tempo. Si tratta dei modelli autoregressivi con input esogeni (AutoRegressive with the eXogenous) ARX, così come AutoRegressive Moving Average with eXogenous (ARMAX) e AutoRegressive Integrated Moving Average (ARIMA). Essi risultano particolarmente utili nell'ambito delle serie di tempo.

Un'ultima forma di analisi di regressione è un'espansione dalla versione lineare abbreviata con la sigla MARS (Multivariate Adaptive Regression Splines) che tiene in considerazione anche dipendenze non lineari e si basa su una tecnica non parametrica.

Un secondo sottogruppo di algoritmi all'interno del mondo del Machine Learning si basano sulla metodologia di combinare algoritmi diversi nell'ottica di migliorare in questo modo le performance che avrebbero se utilizzati singolarmente. La combinazione viene effettuata in un'ottica bagging, ossia lavorando in modo indipendente sugli algoritmi da combinare e poi affiancandoli in modo deterministico, con l'obiettivo di migliorare la robustezza, in un'ottica boosting, ovvero allenando i modelli in sequenza e quindi instaurando una forte dipendenza tra essi, o infine in un'ottica stacking, ossia utilizzandoli in parallelo, ottenendo in seguito un modello riassuntivo che viene allenato in modo da ottenere i risultati di ciascuno di essi e quindi diventa in grado di comprendere le loro prestazioni.

Gli alberi di decisione sono algoritmi particolarmente popolari per i task di classificazione, ma nella forma di regression tree trovano largo utilizzo anche nella regressione. Una procedura comune è utilizzarli in modo bagging. Spesso essi vengono generati sfruttando il metodo statistico del partizionamento ricorsivo, che permette la classificazione dei membri di una popolazione suddividendola ogni volta in gruppi identificati da precisi valori di alcune variabili indipendenti dicotomiche. Anche con le random forest si fa riferimento all'approccio bagging, dal momento che si tratta di regressori ottenuti dall'aggregazione di alberi di decisione e che perdono, così, interpretabilità a causa della complessità. L'aggregazione spesso è casuale e poi guidata verso la migliore performance. Questa soluzione, in particolare, secondo un recente confronto tra i più vari algoritmi di machine learning nella predizione della temperatura indoor, ad opera di Alawadi et Al.[20], che ha previsto la conduzione di un esperimento che ha messo alla prova ben 36 modelli diversi sullo stesso edificio, si rivela la più performante nella determinazione delle variabili energetiche indoor. La combinazione degli algoritmi random forest e dei modelli lineari generalizzati dà vita ai cosiddetti Modelli Lineari generalizzati Random, che riescono a garantire una buona accuracy e allo stesso tempo migliorare l'interpretabilità rispetto alle random forest. Il funzionamento prevede un modello lineare generalizzato, che viene ripetutamente confrontato e adeguato con dei campioni prelevati dal dataset con un successivo reinserimento (campioni bootstrap). L'influenza delle random forest si manifesta però nel fatto che il training viene fatto anche su intervalli casuali delle feature e non solo su porzioni randomiche del dataset di allenamento. Si può riassumere affermando che si tratta di modelli lineari generalizzati il cui training avviene in modo comparabile a quello di una random forest. L'interpretabilità non è sicuramente al livello dei modelli di regressione lineari che sono in grado di evidenziare dei coefficienti di regressione per ciascuna variabile, ma sicuramente, analogamente al Lasso, questo metodo consente un diradamento dei predittori che

produce un output più compatto e di conseguenza più interpretabile.

All'interno della categoria relativa alle tecniche boosting, invece, si può citare il metodo Gradient Boosting: si spingono algoritmi relativamente deboli, tipicamente alberi di decisione (GrTree) oppure regressori lineari (GrLm) a ottimizzare una funzione costo e si scelgono iterativamente le soluzioni che permettono una direzione negativa nel gradiente. Nei modelli di boosting generalizzato (GBM) la struttura è simile a quella di una random forest, ma gli alberi di decisione componenti non vengono costruiti in modo indipendente. Dal punto di vista puramente statistico, le random forest sono progettate per ridurre la varianza nella predizione, mentre i modelli GBM puntano più a ridurre il bias di predizione, ossia la tendenza sistematica a deviare dal valore medio. Di questi ultimi, esistono versioni sviluppate recentemente quali XGB e LGB, dove il problema dell'overfitting cerca di venire superato, senza rinunciare all'efficienza computazionale.

Un'ultima classe di regressori associabili al ramo classico del machine learning fondato maggiormente sulla pura statistica sono le Support Vector Machine. Il loro funzionamento si basa sull'identificazione di tratti che approssimino le osservazioni in base alle variabili prese in considerazione, ottenendo così un set di vettori di supporto che possano poi comporre la funzione di regressione finale.

Anche nella branca del reinforcement learning si trovano esponenti ampiamente utilizzati per fini predittivi all'interno di edifici, ad esempio gli algoritmi genetici, particolarmente utilizzati nell'ambito dei modelli gray-box.

Si conclude analizzando un'ultima grande area del Machine Learning su cui ultimamente si è concentrato molto interesse, quella relativa alle reti neurali artificiali, modelli computazionali con una struttura composta da strati di neuroni, ispirati alle reti di neuroni biologiche. Una rete neurale consiste in gruppi discreti di neuroni, detti layer, tra loro connessi, ed è un sistema in grado di adattare la propria struttura in base alle informazioni che processa ed elabora. Gli strati raggruppano neuroni caratterizzati da simili funzioni di attivazione, con relativo bias, e sono quindi definibili come blocchi di operazioni: ne consegue che ogni layer introduce un errore di approssimazione dipendente dal tipo di funzione di attivazione che tenta di modellare il comportamento della serie storica rappresentata dai dati di training. Tra questi strati, uno riceve le informazioni, ed è chiamato strato di input, mentre il suo strato simmetrico, che trasmette gli output all'utente, è detto strato di output. Gli strati mezzani sono detti strati nascosti e i neuroni qui presenti non interagiscono in alcun modo con l'interfaccia utente; in realtà, la presenza di questi strati è facoltativa, diversamente dalle prime due tipologie. La crescente attenzione che le vede oggetto è giustificata dalla capacità di modellare relazioni intricate e allo stesso tempo presentare dei costi di utilizzo relativamente bassi. L'ispirazione biologica consiste nel mimare la capacità dei neuroni umani di apprendere. Infatti, attingendo dai dati storici forniti nella fase iniziale di training, le reti neurali sono in grado di aggiustare i pesi delle connessioni fra i neuroni e generare così output

aderenti alla realtà. Per questo motivo, i dati usati in questa fase devono coprire un range operativo il più vasto possibile, e la copertura dei dati all'interno di questo intervallo deve essere auspicabilmente uniforme: si parla più in generale di dati di alta qualità. Per mantenere le reti aggiornate, si utilizzano metodi come quello sliding window, che consente alle reti di adattarsi al cambiamento, rimpiazzando vecchi dati di training con nuovi dati in ingresso. Un accorgimento importante consiste anche nella preventiva normalizzazione dei dati in input, in modo da evitare l'effetto dominante delle variabili con un dominio più esteso. Il training può essere sia di tipo supervised che unsupervised: durante questo processo, iterato per un certo numero di volte, ognuna denominata epoca, alla rete vengono forniti i valori in input più il valore in output anticipato, nel caso supervised. E' necessario assegnare i giusti pesi alle connessioni tra gli strati, con il supporto di un adeguato algoritmo di training, in generale la retropropagazione dell'errore: questo metodo caratteristico cerca di ridurre l'errore ottenuto nell'iterazione precedente modificando i pesi fino al termine delle iterazioni fissate, di solito approssimativamente 500. Ne sono una specificazione Levenberg-Marquardt o l'algoritmo di regolarizzazione bayesiana, forse tra i più frequenti tra i modelli relativi al settore dell'efficientamento energetico degli edifici: il primo si distingue per la velocità di convergenza che riesce comunque a minimizzare l'errore quadratico medio, mentre il secondo minimizza invece la combinazione lineare di errori quadratici e pesi così da garantire buone capacità di generalizzazione. Le connessioni vengono ulteriormente aggiustate nella successiva fase di testing, che misura l'aderenza, in accordo agli indicatori di performance selezionati, degli output previsti a quelli reali per quanto riguarda una porzione di dataset alla rete sconosciuta. Segue l'ultima fase, quella di validazione, dove la rete viene messa alla prova su un dataset completamente separato dal set di training: ad esempio, si può attingere a dati provenienti da un'altra stagione o da un altro luogo. Di solito, il training set occupa approssimativamente il 70% dei dati totali, mentre le fasi di validazioni e testing si spartiscono il resto, di solito in proporzione 15% a testa.

Di reti neurali esistono diverse tipologie. L'architettura RNN (Recursive Neural Network) è una delle più note e prevede strati di neuroni connessi sequenzialmente, cosicché l'output di uno strato rappresenta di solito l'input del successivo. Al contrario, le reti neurali convoluzionali (CNN) non presentano cicli al loro interno, si basano quindi su un approccio feed-forward e sono soprattutto efficaci nel riconoscimento, perciò meno utilizzate in letteratura per lo scopo preposto. Tra le reti RNN si possono citare la classe Liquid State Machine (LSM), la classe Long Short Term Memory (LSTM), la classe Gated Recurrent Unit (GRU) e infine la classe Bayesian Regularized Neural Network (BRNN), basata sulla regolarizzazione di tipo bayesiano, particolarmente utile con esigenze di generalizzazione. Si tratta di tipologie che hanno trovato frequenti applicazioni nel campo. Allo stesso modo, anche reti di natura MLP (Multi Layer Perceptron), reti neurali multistrato di tipo

feed forward con un tipo di attivazione non lineare dei neuroni, il che distingue questa tipologia da altre generiche tipologie multistrato feed forward. Le proposte in questo senso hanno riguardato sia reti neurali che si appoggiano sulla regressione generalizzata (GRNN), reti neurali che vengono combinate tramite un approccio ensemble e che forniscono come output la media fra i vari risultati proposti (AvNN), reti neurali i cui pesi relativi ai neuroni negli strati nascosti non necessitano di venir specificati (Extreme Learning Machine, ELM), e infine reti che presentano connessioni fra livelli diversi, ma non fra unità appartenenti allo stesso strato (Deep belief Neural Network, DNN). Una delle tipologie di reti RNN che si trovano più frequentemente applicate alle serie storiche sono le reti NARX (Nonlinear AutoRegressive models with eXogenous input), una tipologia di rete dinamica ricorrente, dove gli output non dipende soltanto dagli input agli istanti corrente e precedenti, ma anche dai valori degli altri output all'istante corrente e agli istanti precedenti. In generale, si può affermare che i modelli statistici sono lineari e tempo invarianti: limiti che possono facilmente diminuirne l'accuracy in contesti di forte non-linearità ed incertezza.

Concludendo, si menziona nuovamente lo studio ad opera di Alawadi et Al. [20], dove si è illustrato un confronto tra modelli dove gli indicatori di performance scelti sono stati RMSE e il coefficiente R, così da individuare non solo l'inesattezza nella previsione, ma anche ottenere un'indicazione della capacità di generalizzazione. I valori sono stati calcolati, per ogni algoritmo, come la media dei valori raggiunti nei 10 tentativi a disposizione. I risultati vengono visualizzati tramite il rank di Friedman, che prevede l'ordinamento in ordine decrescente in base alla performance ottenuta sui diversi dataset, quindi su diversi intervalli di tempo. Tra i modelli risultati come migliori compaiono i modelli boosted basati sul gradiente che includono alberi di regressione, random forest, SVR e tra le reti neurali spiccano le AvNN e i modelli extreme learning. L'esperimento mette in luce, inoltre, che i modelli random forest dimostrano una maggior robustezza e una minore sensibilità agli outlier e al rumore.

Alcuni modelli black-box presenti in letteratura

Afroz et Al. [21] L'obiettivo consisteva nella predizione della temperatura interna all'interno di un edificio istituzionale, situato in Australia. il dataset era costituito da dati raccolti per un periodo di 13 giorni all'interno di ottobre, nella stagione primaverile, a intervalli di 5 minuti. I parametri in input sono stati selezionati e ridotti a un numero di 25, prima basandosi sulla consulenza di esperti di dominio, e poi sui risultati del modello scelto in funzione dei parametri fissati. Per raggiungere i migliori livelli di MSE e R, i parametri più significativi si sono dimostrati la temperatura di set-point, la temperatura esterna, la velocità del vento, la direzione del vento, la pressione barometrica, la temperatura del punto

di rugiada e l'umidità relativa. la scelta del modello da utilizzare è ricaduta sulle reti neurali artificiali per la loro risaputa superiorità nello sviluppo delle serie storiche, in particolare su una tipologia NARX, in grado di predire il valore futuro di una serie di tempo dalla serie storica stessa e da una seconda serie storica a essa legata. L'algoritmo specifico di training, invece, è stato stabilito dopo aver comparato le performance di tre diverse alternative: la regolarizzazione bayesiana, Scaled Conjugate Gradient e l'algoritmo di Levenberg-Marquardt, una tipologia di algoritmo di back-propagation, che è risultato essere il migliore in termini di una predizione a breve termine della temperatura, sulla base dei criteri MSE, R e tempo per ogni iterazione. in particolare, Levenberg-Marquardt e la regolarizzazione bayesiana mostravano i minori valori di MSE, ma i più alti valori di R; il secondo era però penalizzato da un più proibitivo tempo computazionale, mentre L-M si dimostra come previsto l'algoritmo più veloce nel convergere. la validazione del risultato è stata effettuata tramite l'analisi residuale plottando la funzione dell'autocorrelazione dell'errore per ogni algoritmo, che auspicabilmente avrebbe dovuto essere non nulla soltanto a zero e rappresentare l'MSE, e così non è stato per SCG. il testing è stato, infine, effettuato grazie a due diversi data set collocati in due stagioni estreme (inverno ed estate), sempre a partire dalla stessa località, per provare la robustezza del modello.

Spencer et Al. [22] Il banco di prova in questo caso è una smart home, dotata di circa un centinaio fra sensori ed attuatori, che raccolgono dati con intervalli di 15 minuti. L'obiettivo era minimizzare il consumo comprendendo se fosse necessario o meno attivare il sistema HVAC sulla base della temperatura corrente, prevista da un'ora fino a 24 ore. Un altro aspetto da prendere in considerazione era la capacità di tamponare un eventuale guasto dei sensori, quindi comprendere di quanti dati al minimo necessitasse la funzione per essere affidabile. la procedura si è basata su una funzione di regressione, dove i parametri di dipendenza della funzione di output dagli input provenienti dai 18 sensori per ogni intervallo di tempo misurato sono stati identificati minimizzando la somma residua dei quadrati, inizialmente ponendo l'intercetta uguale al valore medio in output e il coefficiente di dipendenza nullo (secondo la procedura chiamata forward stepward linear resolution). Per stimare il numero migliore di predittori, è stato misurato l'indicatore BIC (Bayesian Information Criteria) in modo da stimare l'overfitting del modello, ritenuto un fenomeno altamente probabile, e RMSE e MAE, identificando 9 variabili principali: le temperatura nelle due zone, l'illuminazione, il contributo solare sulla parete, la temperatura esterna, e trascurando ad esempio la variabile relativa alla velocità e direzione del vento. le previsioni mostrano la maggiore accuracy e i migliori valori di RMSE e MAE con uno storico di 8 letture rispetto a 4, quindi è possibile ricominciare a prevedere con accuratezza circa dopo 75 minuti dopo un guasto dei sensori.

Mustafaraj et Al. [23] La zona presa in considerazione è un open office locato in un edificio moderno di Londra. Il dataset includeva dati su un intervallo di tre mesi utilizzati per prevedere a distanze da 30 a 3 ore la temperatura dell'aria interna e l'umidità relativa. Per stabilire l'orizzonte temporale di previsione più adeguato, sono stati utilizzati criteri come la bontà di fit, MSE, MAE e un coefficiente di similarità fra gli output del modello e i dati reali. L'esperimento ha dimostrato la superiorità del modello autoregressivo non lineare basato su rete neurale (NNARX) rispetto al corrispettivo lineare parametrico (ARX). Le variabili in input includono la concentrazione di anidride carbonica per stimare l'occupazione dell'ufficio, di solito stimata in base all'ora e alla tipologia di giorno (lavorativo/non lavorativo). escludendo i giorni festivi, dove gli impianti erano spenti, si sono selezionate grazie all'analisi dei dati le variabili in input più correlate a quelle in output, relative agli impianti, agli apporti interni e all'ambiente esterno. E' stata identificata la struttura ottimale dei modelli individuando i parametri minimizzando l'errore finale di predizione di Akaike (FPE), utilizzando il metodo iterativo Gauss-Newton per il modello lineare, e l'algoritmo di Lvenberg-Marquardt, unito all'algoritmo di pruning obs per evitare l'overfitting, per il modello non lineare. Il modello d'ordine e l'intervallo di tempo ottimali sono stati poi stimati in base a MSE e MAE. La validazione, invece, si condotta in base alla bontà del fit (G) e al coefficiente di determinazione (R^2), in grado di quantificare la distanza dalla media della predizione rispetto alla distanza dalla media del dato sperimentale. La validità dei modelli non è più garantita oltre le 3 ore, mentre il time lag migliore è 10 minuti. Il modello non lineare si rivela più efficace, perché le variabili in output sono governate da equazioni di diffusione non lineari.

Soleimani-Mohsen et Al. [24] Un'analisi con un obiettivo simile viene portata avanti sulla base dei dati su un orizzonte di 12 giorni, con un intervallo di misurazione di 10 minuti, riguardanti una stanza di un edificio residenziale, utilizzato come ufficio e quindi dotato di molti dispositivi elettrici. Le variabili in input considerate sono la temperatura dell'aria esterna, il consumo elettrico della stanza, la temperatura dell'aria interna, l'ora del giorno, la temperatura operativa misurata, in questo caso identificato come l'output del modello. nel caso lineare, si è utilizzato il metodo dei minimi quadrati per il calcolo della funzione che lega l'output agli input, mentre nel caso non lineare si è optato per l'algoritmo Levenberg-Marquardt. Una conferma è stata ottenuta anche tramite una stanza adibita a laboratorio e quindi climatizzata. Il dataset in questo caso copriva un intervallo di tempo di 70 ore e il campionamento era effettuato ogni 5 minuti. Le variabili identificate come input sono state la temperatura operativa, il tasso di ventilazione (litri/sec), la temperatura dell'acqua nei tubi al di là del muro, la potenza totale assorbita dalla stanza (W), la temperatura media ottenuta come la media di ogni coppia di misurazioni. Sulla base delle misure di performance MSEE (Mean Squared

Estimation Error), MAEE, MAXERR, viene confermata anche in questo caso la superiorità del modello non lineare.

Huang et Al. [25] In questo caso, una rete neurale artificiale è stata applicata a un ambiente multi-zona all'interno di un edificio commerciale. Il dataset copriva il periodo di gennaio ed includeva circa 4500 misurazioni, mentre per validazione e testing sono stati utilizzati periodi di sei giorni, in febbraio e in estate rispettivamente. Le variabili più influenti sono state selezionate e normalizzate così da impedire una maggiore influenza da parte di quelle con un intervallo di dominio più vasto. L'ordine iniziale ad esse assegnato è stato 1. In seguito, si è fatto riferimento agli indicatori di performance MAE e RMSE per valutare le performance del modello, così da ottenere l'ordine ottimale assegnato a ciascuna variabile in input e tarare lo strato nascosto, mentre i parametri di training venivano mantenuti costanti. L'algoritmo di training selezionato è stato la regolarizzazione bayesiana, così da poter ottenere una sufficiente generalizzazione, anche se a scapito della velocità di convergenza. Per implementare la versione multizona, si è utilizzato l'approccio MIMO (Multi Input Multi Output), ripetendo l'intero processo e fornendo in input le stesse variabili ma riferite a ciascuna zona, ottenendo così un output riferito all'istante richiesto per ciascuna zona. L'esperimento ha dimostrato che il modello riesce ad essere accurato pur con un ordine limitato di input (in questo caso 4) e con un numero altresì contenuto di strati nascosti.

Juan et Al. [26] I dati utilizzati sono stati ottenuti simulando un edificio tramite il software Tekton 3d, a Màlaga. Il dataset copre un periodo di 1 anno, con misurazioni effettuate ogni ora. Le variabili misurate inizialmente sono 18, con l'obiettivo di prevedere le temperature delle quattro zone nell'orizzonte di un'ora. Le variabili più rilevanti si sono dimostrate il mese dell'anno, il giorno della settimana, il giorno del mese, l'ora del giorno, l'umidità relativa, la temperatura esterna, la temperatura di set point, la potenza termica richiesta dalla stanza, la temperatura corrente della stanza confinante. Dopo essere state sottoposte a standardizzazione, si è utilizzato l'approccio autoregressivo, poi la regressione lineare multipla (MLR e RMLR), una rete neurale tradizionale (MLP), una sua specificazione in versione NARX, che come già accennato si dimostra di solito adeguato in presenza di serie temporale, e inoltre una tipologia più innovativa, la Extreme Learning Machine. Se in generale per quanto riguarda l'indicatore MAE il modello NARX risulta il più performante, se si antepone un'analisi basata sul clustering, in particolare sul DbScan, risulta che i modelli lineari e in special modo RMLR riescono a beneficiarne, ma non per via di un miglioramento del MAE, ma al contrario di un peggioramento del MAE riguardante i modelli non lineari.

Saltuk et Al. [27] Se spesso l'orizzonte di previsione non si spinge oltre le tre ore, in questo esempio, che prende come oggetto una serra, l'obiettivo primario è stato quello di allungarlo il più possibile. La serra si trova nella provincia di siirt nell'anatolia del sud-est. L'algoritmo di training scelto è stato anche questa volta quello di Levenberg-Marquardt. le variabili in input sono state identificate come: l'umidità interna, la temperatura esterna, l'umidità esterna, la pressione relativa, la pressione assoluta, la velocità del vento, la temperatura di rugiada, la temperatura interna storica, la temperatura del vento, il tasso di ventilazione, e sono state successivamente normalizzate. Le misurazioni ammontavano a circa 8000 e riguardavano tutti i mesi di utilizzo della serra. per stimare i parametri della rete, è stato necessario basarsi su alcuni indicatori di performance quali R^2 , R, MSE e il tempo di iterazione. Il trend evidenziato durante i test dimostra che l'architettura con maggiore numerosità consente di raggiungere gli errori minimi, passando da un MSE medio totale di 1,63 a uno di 1,47 con 25 neuroni a fronte di 5, a prezzo, naturalmente, di un aumento del tempo computazionale. La notevole mole di dati disponibili ha permesso di ottenere predizioni su un orizzonte di 6 ore per quanto riguarda l'umidità interna, e anche 3 giorni per quanto riguarda la temperatura, senza nemmeno disporre di dati in input riguardanti la componente solare.

Hermawan et Al. [28] Si tratta di un'applicazione in un contesto particolare, dove ancora una volta è stata dimostrata l'adeguatezza dei modelli black-box: un edificio antico, particolarmente suscettibile al clima esterno, in ambiente tropicale, dove le misurazioni sono state prese ogni ora dalle 6 alle 22, per cinque giorni per ogni stagione, arrivando così a 20 giorni. Nei paesi con clima estremi, c'è una maggiore tendenza a vivere al chiuso e per questo motivo la climatizzazione adeguata ed efficiente rimane una priorità. Il modello è un modello di regressione lineare, con parametri diversi stimati per ogni stagione, che è stato validato sulla base della validità e della robustezza, dopo aver ipotizzato che le variabili in ingresso fossero normali, prive di eteroschedasticità e multicollinearità. E' emerso che in contesti così estremi e con alcune tipologie di materiali da costruzione, come la pietra, e specialmente con edifici esposti, il contributo preponderante per la determinazione della temperatura dell'aria interna era fornito dalla temperatura esterna.

Mellouli et Al. [29] Questo modello si basa sull'applicazione di un modello di rete neurale ancora poco utilizzato a tal fini, la rete lstm, ad una cold room. I modelli sono stati applicati a vari dataset, dell'intervallo di alcuni giorni, o all'unione di essi, con misurazioni effettuati ogni 5 secondi a causa della particolarità del luogo. Essa è stata considerata in quattro varianti: LSTM classica, convoluzionale, stacked, bidirezionale. dopo diversi tentativi, si è scelto di fissare 1024 unità, una funzione

di attivazione lineare e una funzione di costo che prendeva in considerazione RMSE per la rete classica, con le relative modifiche per le altre varianti. Tra le variabili in ingresso figurano il booleano per l'attività del compressore, il periodo della risposta alla domanda, il periodo di defrost, la temperatura esterna, il tempo trascorso dall'ultimo defrost e dall'ultima cancellazione. tramite gli indicatori di performance fit, MSE, RMSE, MAE si osserva che la lstm tradizionale e la convoluzionale sono meno sensibili al rumore, mentre d'altro canto le altre due, specialmente la versione stacked grazie alla sua abilità di auto apprendimento, garantiscono migliori performance a meno di scarsità di dati, pur essendo molto sensibili al rumore, tanto da mostrare un'impennata al momento dell'attivazione del sistema elettrico.

Huang et Al. [30] Lo studio illustra la possibilità di dettagliare le variabili di input al di là delle temperature delle zone adiacenti, soluzione che era già stata in grado di apportare notevoli miglioramenti. L'esperimento ha utilizzato come target l'aeroporto di adelaide, con dati raccolti nel mese di gennaio. Si è scelto un modello di rete neurale MLP, la cui struttura non lineare viene descritta tramite un approccio NARX. Per identificare le variabili in input più opportune, si utilizza un criterio lineare di selezione feed-forward; in seguito l'ordine associato a ciascun parametro e il numero di strati nascosti vengono definiti in modo da ottimizzare le performance. La normalizzazione si rende necessaria per abbreviare il tempo di training. Il tradizionale approccio mimo per le aree multizona consente di identificare un vettore di input, ciascuno con il proprio storico, associato a ciascuna delle variabili in output, nonché lo storico delle variabili in output per l'allenamento, ed include tra le variabili in input i vettori con lo storico delle temperature adiacenti. In questo specifico caso, si è adottato un approccio MISO (Multi Input Single Output), che ha permesso di stimare la temperatura di una sola zona, basandosi però anche sul vettore delle temperature storiche delle zone adiacenti. Si tratta di una soluzione più modulare e meno complessa, che permette comunque di giungere a una risposta globale tramite l'unione dei risultati. Le variabili selezionate aggiuntive risultano essere la temperatura esterna, la percentuale di apertura della valvola dell'acqua di raffrescamento, la sua portata e la sua temperatura. L'algoritmo di training selezionato si basa sulla regolarizzazione bayesiana. Pesi e bias all'interno dello strato nascosto, invece, sono stati inizializzati tramite il metodo Nguyen-Widrow. I criteri di valutazione hanno incluso mse, mae e me (maximum error). si dimostra che, come teorizzato, l'inclusione della temperature delle zone adiacenti apporta grandi miglioramenti. L'orizzonte di previsione rimane di un paio di giorni, ma si auspica che associando il modello alle previsioni del tempo sarà possibile ottenere una visione ancora più lungimirante.

Royer et Al. [31] Si tratta di un altro utilizzo dell'approccio MIMO, per calcolare la temperatura delle zone di un edificio universitario "a forma di U"

teorizzato e modellato tramite il software EnergyPlus, così da azzerare i costi di raccolta e il tempo di attesa. Il sistema viene rappresentato da una serie di variabili di stato, che formano uno spazio vettoriale e che sono espresse da un vettore di input, dal loro stesso storico e da una componente di disturbo. La variabile di output ad un dato tempo t , quindi, dipende dagli stessi vettori in input al tempo t , dalle variabili di stato al tempo t e al disturbo al tempo t . I parametri caratterizzanti l'equazione devono venire determinati, così come l'ordine sufficiente per un'appropriata descrizione del modello. Il vettore di input viene popolato con la temperatura esterna, la temperatura di setpoint, la radiazione solare diretta, la potenza associata all'impianto. La scalabilità del modello viene provata considerando come zona termica prima una singola stanza, poi un piano, determinandone la temperatura come una media pesata per il volume delle zone componenti, poi dell'edificio completo; inoltre, la simulazione è stata effettuata a partire dallo stesso edificio, ma in località differenti. L'indicatore di performance principale per la validazione è stato il fit di NRMSE, una percentuale in grado di caratterizzare l'aderenza ai valori del dataset di validazione, con un orizzonte di predizione da 3 a 24 ore, osservando una naturale diminuzione delle performance, pur rimanendo su una soglia pienamente accettabile.

Zamora-Martinez et Al. [32] Lo studio si concentra sul SMLsystem (Small Medium Large), una casa presso l'università Ceu Cardenal Herrera alimentata tramite pannelli solari e un sistema dhw e progettata per essere energeticamente indipendente. Si tratta di un ambiente multizona, quindi collocabile nell'ambito MIMO. Le variabili inizialmente tenute in considerazioni sono state la temperatura interna, l'ora del giorno, l'irradianza solare (w/m^2), la percentuale di umidità relativa, la qualità dell'aria interna in CO2 ppm, un booleano che esprime se si sta verificando precipitazione. Si sono applicati modelli di predizione provenienti dal ramo statistico (Exponential Smoothing e ARIMA), entrambi ottimizzati tramite il criterio informativo di Akaike, e una rete neurale per quanto riguarda l'ambito machine learning, previa naturalmente normalizzazione dei dati. La validazione è stata fatta tramite gli indicatori MSE, MAE, RMSE, SMAPE. L'algoritmo scelto per identificare i pesi nella struttura della rete e minimizzare la funzione mse è una tradizionale versione del ben noto algoritmo di error-backpropagation. L'orizzonte di previsione è stato fissato a tre ore, utile per le finalità di utilizzo. Se in ogni caso la rete neurale performò meglio rispetto all'approccio statistico, l'indicatore smape evidenzia inoltre che se prima dell'orizzonte delle tre ore è sufficiente basarsi sullo storico della temperatura interna e sull'ora del giorno, superata questa soglia è necessario arricchire il range di variabili in input con l'irradianza solare, e questo trend rimane in generale valido allargando la prospettiva.

Afroz et Al. [33] Questo esperimento si focalizza su un edificio commerciale all'interno dell'area della Murdoch University, un edificio con frequenti cambiamenti di occupazione e quindi con perdite o innalzamenti di calore significativi. Si insiste sull'importanza di adottare un regime metodologico nella scelta dei parametri in input, accertandosi comunque che rimangano indipendenti tra loro per non creare ridondanza ed effettuando tagli nel momento in cui non c'è più una crescita sensibile dell'accuracy. Si sceglie il modello rnn narx perché ritenuto più adeguato a trattare dati storici, e si procede in un'ottica sia miso che mimo, variando i parametri in input, per identificare lo scenario migliore. Il dataset copre un intervallo di tempo di ben tre anni, suddiviso in categorie relative alle stagioni, e con una frequenza di campionamento di 5 minuti. Gli attributi in input vengono selezionati utilizzando lo strumento Regression Learner di Matlab, che, partendo da un set vuoto, continua ad aggiungere le variabili in input in modo tale da ottenere il valore più alto della funzione obiettivo. La validazione è fatta paragonando le performance in base alla velocità, accuracy e complessità, rispettivamente rappresentati da RMSE, MAE, R^2 e tempo di iterazione: il modello più performante è risultato dotato di 12 variabili, l'entalpia dell'aria esterna, la pressione barometrica, la temperatura dell'aria di ritorno, l'umidità, il punto di regolazione della pressione statica del condotto dell'aria di mandata, la posizione della valvola per l'acqua calda, la pressione differenziale dell'acqua di raffreddamento, la pressione differenziale dell'acqua calda, la potenza al terminale, la posizione del sensore in termini di centro e perimetro. L'analisi è stata condotta sia in un'ottica miso che mimo, osservando che la struttura mimo si rivela più affidabile a causa della migliore capacità di data fitting, inoltre necessita di dataset di dimensione minore, riducendo così il tempo di training. D'altra parte, si è confermato anche che l'affidabilità della predizione si deteriora con l'allungamento dell'orizzonte di predizione, qui portato da 5 minuti (uguale alla frequenza di campionamento, quindi singolo time step) a 28 giorni.

Killian et Al. [34] Lo studio prende in considerazione un edificio universitario a salisbugo abbastanza complesso, che conta ben cinque piani. Il funzionamento del modello si basa su una logica fuzzy. Il dataset includeva una settimana di tempo e raccoglieva variabili quali la temperatura dell'aria di ventilazione, la temperatura ambiente, l'irradianza e il tasso di occupazione in percentuale per ogni zona, in un'ottica di tipo miso, fornendo quindi in output la temperatura interna all'istante t . La logica fuzzy è stata d'aiuto nell'identificazione dei parametri del modello ARX. La validazione è stata effettuata sfruttando gli indicatori RMSE e R^2 , con un orizzonte di predizione da 12 a 36 ore. Al modello si riconduce un trend di sottostima, d'altro canto però si sottolinea che le prestazioni sono sorprendentemente alte nonostante la dimensione ridotta del dataset, che copre una settimana di tempo e con un periodo di campionamento di un'ora.

Li et Al. [35] Questa ricerca opta per una rete neurale di tipo elman che possa predire la temperatura interna nell'ambito dei sistemi di condizionamento VAV (Variabile Air Volume). Il controllo predittivo potrebbe costituire una significativa stabilizzazione del convenzionale controllo pid la cui variabile osservata è la temperatura interna e la cui variabile controllata è l'angolo di apertura della valvola. il tempo necessario affinché una sollecitazione abbia effetto, secondo il coefficiente d'inerzia, è di circa 5 minuti, che diviene quindi l'orizzonte di predizione. Gli input ricevuti dalla rete sono l'angolo di apertura corrente della valvola che regola l'immissione dell'aria e la velocità della ventola; il suo output è la temperatura misurata e il disturbo del sistema è il valore corrente della temperatura dell'aria immessa. Per verificare il corretto funzionamento del controllo sotto le istruzioni del modello, si sono spalancate per un periodo di tempo di circa 150 minuti le finestre della stanza monitorando la temperatura, che si è sempre mantenuta in linea rispetto a quanto richiesto, grazie alla mitigazione automatica della ventilazione.

Mba et Al. [36] L'esperimento è stato portato avanti nelle peculiari condizioni ambientali della città di Douala, in Camerun. Il dataset includeva campionamenti orari nell'arco di 24 mesi, inizialmente riguardanti i valori della temperatura dell'aria interna esterna ed interna e le umidità relative, con l'obiettivo di ottenere in anticipo umidità e temperature interne. Si è optato per l'architettura più frequentemente utilizzata in riferimento alle reti neurali, una struttura multistrato di tipo MLP, per cui è comunque stato spesso provato che un singolo strato nascosto fosse sufficiente per approssimare qualsiasi funzione con l'accuracy desiderata. I parametri di weight e bias che caratterizzano le relazioni fra gli strati sono stati ottenuti, come di consueto, minimizzando la funzione d'errore, in questo caso la somma dei quadrati degli errori fra l'output del modello e quello sperimentale. L'algoritmo specifico di training è stato identificato nell'algoritmo di Levenberg-Marquardt grazie alla sua capacità di individuare un buon trade off tra tempi computazionali e minimo mse. nella seguente fase di generalizzazione, il modello è stato messo alla prova con diversi orizzonti temporali di previsione, da un giorno fino a un mese. L'analisi statistica successiva, tramite regressione lineare e confronto delle due funzioni lineari, sui valori ottenuti rispetto a quelli reali dimostra la validità dei risultati. Come noto, il coefficiente R medio peggiore è relativo all'orizzonte di predizione più lungo; anche in questo caso, risulta evidente l'aumento del tempo computazionale con l'aumento di numerosità della struttura, così come con l'aumento del numero di input. Il tempo di predizione più lungo, infatti, si riferisce al modello numero 3, con un numero di input pari a 48, rispetto ai 36 degli altri due modelli provati, e una numerosità di 20 neuroni, e sfiora i 25 minuti.

Liab et Al. [37] Questa proposta si distingue per la peculiarità del modello utilizzato, un modello svm, sicuramente meno in voga nell'ambito della predizione

delle variabili energetiche negli edifici rispetto alle più gettonate reti neurali. Si sottolinea che si tratta di un metodo tuttavia molto promettente, soprattutto perché adotta il principio della struttura della minimizzazione del rischio, che minimizza il limite superiore dell'errore di generalizzazione e che si è rivelato spesso superiore alla versione tradizionale ed empirica utilizzata dalle reti neurali convenzionali e che si limita a minimizzare l'errore di training. I parametri in input considerati sono stati la temperatura dell'aria esterna, l'umidità relativa, l'irradianza solare (W/m^2), su un intervallo di 2 ore e sono stati preventivamente normalizzati per migliorare l'efficacia del calcolo. la relazione fra l'output (in questo caso, diversamente da altri modelli considerati finora, il carico termico orario necessario) e gli input viene modellata tramite parametri determinati minimizzando la funzione di rischio. Viene poi compiuta una seconda scelta riguardante la funzione di kernel, optando per la gaussiana in quanto di frequente utilizzo. Nello specifico, è stato necessario identificare il parametro di larghezza della gaussiana, il parametro di penalità c direttamente proporzionale al numero di data points selezionati come support vector e conseguentemente all'overfitting, e il raggio epsilon, a esso in controfase. Allenato su un dataset con campionamenti orari che comprendeva il mese di maggio, il modello è stato poi validato su dataset relativi ad altri tre mesi utilizzando gli indicatori MRE (mean relative error) e rmse e ha dimostrato una leggera superiorità rispetto al modello più quotato basato sulla back propagation.

Xu et Al. [38] Anche questo studio si incentra su una tecnica di Deep Learning relativamente nuova nel campo, le reti LSTM, tipologia di rete rnn introdotta per superarne i problemi riconducibili al gradiente. Questo modello viene applicato a un ufficio nella provincia di henan. l'intervallo di tempo coperto dal dataset di training è di due mesi, con campionamenti ogni 5 minuti. D'altro canto, l'orizzonte di previsione parte, come di consueto, da un singolo time step di 5 minuti fino a 30 minuti così da verificare l'abilità del modello di effettuare previsioni multi-time step. Nel caso di predizione one-time step, le performance del modello vengono paragonate a quelle di altri modelli preesistenti, come un decision tree, un modello classico di rete neurale basato su back-propagation, e un modello SVM sulla base di indicatori come RMSE, MAPE, R^2 e d_{stat} . Se il modello BPNN non sembrano adeguati specialmente quando il sistema di condizionamento è attivo, le prestazioni del modello LSTM si dimostrano molto buone, anche tenendo conto della scarsità di variabili in input (solo 6 time-step precedenti), soprattutto per quanto riguarda l'accuracy della predizione direzionale, misurata tramite d_{stat} .

Ruano et Al. [39] A partire da un dataset popolato a partire da un edificio scolastico nel sud del portogallo, con attributi quali la temperatura e l'umidità dell'aria esterna, l'irradianza solare, la velocità del vento e la direzione del sensore ricevente per l'esterno, e per l'interno, oltre alla temperatura e umidità, anche lo

stato di apertura o chiusura delle porte e finestre, la potenza consumata dall'aria condizionata, la portata dell'acqua e la temperatura dell'acqua, si è allenata una rete neurale RBF (Radial Basis Function), con una trasformazione non lineare dal primo strato a quello nascosto, e lineare dallo strato nascosto a quello di output. I dati coprivano un intervallo di 10 giorni con un periodo di sampling di 5 minuti, più una finestra di 3 giorni per il testing, e 1 per la validazione e la comparazione. L'algoritmo utilizzato per identificare i parametri non lineari è stato il ben noto levenberg-marquardt. Dal momento che si è osservato un deterioramento delle performance con dati dissimili da quelli di training (mese di marzo), si verificano i miglioramenti con una tipologia adattativa, in grado di modificare tutti i parametri della rete e non solo quelli legati alla struttura non lineare. E' emerso un rmse notevolmente inferiore per quanto riguarda la prima opzione.

Chen et Al. [40] Un'esigenza frequente è quella del controllo automatico dei sistemi HVAC, spesso ottenuto tramite il metodo planning-based del Model Predictive Control, che è in grado di risolvere il problema del controllo ottimale, anche tenendo conto di diversi obiettivi, e.g. l'energia consumata e il comfort. La soluzione del problema può giungere ricorrendo a modelli physical-based o statistical-based, ricorrendo dunque a una conoscenza dell'edificio oppure a un modello di forma parametrica di esso. Una valida alternativa è rappresentata dai modelli di Reinforcement Learning, che, diversamente dal semplice MPC, sono scalabili, perciò applicabili a diversi contesti, perché in grado di imparare una control policy specifica, pur richiedendo una vastità campionaria molto più significativa. L'obiettivo è dunque allenare il modello su dati storici utilizzando l'imitation learning, così da assumere il controllo ottimale dei sistemi HVAC, tutt'oggi ancora per la maggior parte governati da un controllo proporzionale integrativo derivato o da semplici meccanismi rule-based di tipo on-off. Se i modelli di Reinforcement Learning richiedono notevole complessità dei sample di allenamento e rimangono non interpretabili, la soluzione Gnu-RL adotta una recente policy di Model Predictive Control, che decodifica la conoscenza di dominio, e richiede come allenamento soltanto i dati storici dagli HVAC esistenti, così da risultare sia efficiente rispetto ai dati in input, sia interpretabile. L'allenamento viene effettuato in due periodi, un primo definito offline, dove il modello impara la policy di riferimento tramite Imitation Learning, e un secondo definito online, dove viene ottimizzata la policy (Proximal Policy Optimization). Si deduce che questo algoritmo rientra in uno dei tre generali approcci del Reinforcement Learning, quello dei metodi policy gradients, che ricercano la policy ottimale utilizzando una stima stocastica del gradiente di policy. Il problema viene formulato in modo da essere risolto tramite Differentiable MPC Policy, che individua la traiettoria in grado di minimizzare la funzione di costo e allo stesso tempo rispetta la dinamica dell'edificio. I dati in input necessari sono soltanto gli storici dei controlli HVAC presenti, l'orizzonte

di predizione considerato è di tre ore, e il time-step è dell'ordine dei 15 minuti. Il modello viene validato sia su una simulazione di Energy Plus, dove dimostra un risparmio energetico del 6,6% rispetto ai modelli RL predecessori, sia su una conference room esistente, dove addirittura il risparmio sale di 16,7% rispetto all'esistente metodologia di controllo. Si tratta, inoltre, di un modello totalmente scalabile, per cui sono necessari i termini di stato, azione e di disturbo di interesse per definire la funzione di costo di partenza.

Chen et Al. [41] Anche questa ricerca si basa sulla gestione energetica automatica, implementata grazie a una RNN, che prima impara le complesse dinamiche temporali a partire dalle misurazioni dei profili operativi di consumo di energia, dopo individua il controllo ottimale risolvendo un problema di ottimizzazione con l'obiettivo di minimizzare il consumo energetico su un orizzonte finito di tempo, identificando una discesa iterativa del gradiente manipolando gli input controllabili (e.g. i setpoint di temperatura) per ogni time-step e i relativi input di controllo. Come riferimento, è stato utilizzato il modello RC, un metodo popolare nel MPC con orizzonte finito per modellare le dinamiche termiche. L'ottimizzatore scelto per la rete è SGD (Stochastic Gradient Descent), la funzione di attivazione è ReLU, sono presenti dropout e la perdita è formulata tramite il MSE. Nella prima fase, la rete prende in input ben 55 feature, tra cui variabili controllate come le temperature di setpoint, e variabili non controllate quali le temperature misurate e le occupazioni delle zone, su un orizzonte temporale totale di un anno (il 2004) riferito a Seattle, e di cui 2 mesi sono adibiti al testing. L'edificio di riferimento è un complesso edificio commerciale, suddiviso in 16 zone. La performance del modello è stata misurata con il RMSE, che si dimostra del 68,33% superiore rispetto al modello RC di prim'ordine identificato; quest'ultimo fallisce sistematicamente nella previsione del crollo del consumo energetico dell'edificio nei giorni di weekend, poiché non è in grado di tenere in considerazione la variabile dell'occupancy. Infine, gli input di controllo suggeriti riescono a ridurre il consumo energetico del 30,74% rispetto al caso reale, contro il risparmio di poco più del 4% ottenuto grazie alla soluzione MPC basata sul modello RC, un risultato da imputare alla relazione non lineare fra la temperatura di setpoint e il calore sensibile emanato dai sistemi HVAC.

Ellis et Al. [42] Il lavoro torna a cercare di superare le sfide associate a MPC, cioè il complesso processo di costruzione, configurazione e training dei modelli predittivi se comprendono diversi edifici e il costo del commissioning dei sistemi. Con MPC si intende un controllo che fissa i setpoint minimizzando una funzione di costo economicamente orientata. Il modello sviluppato è un black-box che è in grado di aggirare i costi di costruzione e training del modello. Durante la fase offline, il modello viene costruito e allenato su un intervallo di tempo di 3 mesi: in questa fase la prima sezione del modello (encoder) si occupa di generare

uno stimatore sulla base dei dati di training che funga da inizializzazione per il decoder, la seconda sezione. Nella fase online, il modello viene validato su un edificio generato su Energy Plus, costituito da 5 diverse zone e collocato a Phoenix, in Arizona. Gli output generati sono la temperatura dell'aria interna della zona e il raffrescamento sensibile necessario per raffreddare la zona. In un primo caso ideale, gli input messi a disposizione vanno dalla temperatura di setpoint, dalla temperatura dell'aria esterna, dalla radiazione solare diffusa e diretta, e il carico di energia interno. Dal momento che non sempre questi dati vengono misurati, in un secondo caso pratico vengono considerati invece la tipologia di giorno, l'ora del giorno e il giorno dell'anno, la temperatura esterna e il setpoint. La struttura del modello prevede uno strato LSTM per l'encoder, mentre per il decoder a uno strato LSTM si aggiunge uno strato dense di output con una funzione di attivazione lineare. L'orizzonte di predizione è di due giorni, sulla base di un orizzonte temporale di un giorno nel training. Il successivo controllo ottimale consiste nella manipolazione, invece, della temperatura di setpoint, vincolata a rimanere compresa fra i 23 e i 25 °C.

Capitolo 3

Data preprocessing

In questa sezione vengono dettagliati gli step di trasformazione che sono stati ritenuti opportuni alla creazione di un dataset finale con un contenuto il più possibile informativo per lo sviluppo di un modello black box.

Le operazioni sono state effettuate all'interno dell'ambiente Google Colaboratory, avvalendosi delle ben note librerie Seaborn, Pandas, NumPy e Matplotlib.

3.1 Scope

L'edificio target è un fabbricato adibito a centro di ricerca ed incubatore di imprese che operano nel campo delle energie rinnovabili e verdi; è definito Energy Center e sito in Torino, tra via Nino Bixio e via Borsellino. Alcuni locali all'interno, tra cui l'auditorium, sono a tutt'aria, mentre altri sono riscaldati con impianti a radiatori e aerotermi senza aria primaria; invece, nel piano interrato per la zona ristorante e nel piano terra per la zona aria la climatizzazione si appoggia a pannelli radianti a pavimento e aria primaria. Come indicato in figura 3.1, si identifica come zona target la sezione Nord-Est dell'edificio, sul lato B, che include 5 uffici per ciascun piano, e che sono climatizzati tramite pannelli radianti a soffitto, alimentati attraverso un apposito circuito, e aria primaria.

I dati di riferimento sono raccolti con una frequenza di campionamento di 4 volte all'ora, su un intervallo di tempo di circa undici mesi, a partire da sensori localizzati in tutti e 15 gli uffici citati, qui codificati con le sigle R38, R39, R40, R42, R45, a cui si concatena P1, P2 o P3 in funzione del piano di appartenenza.

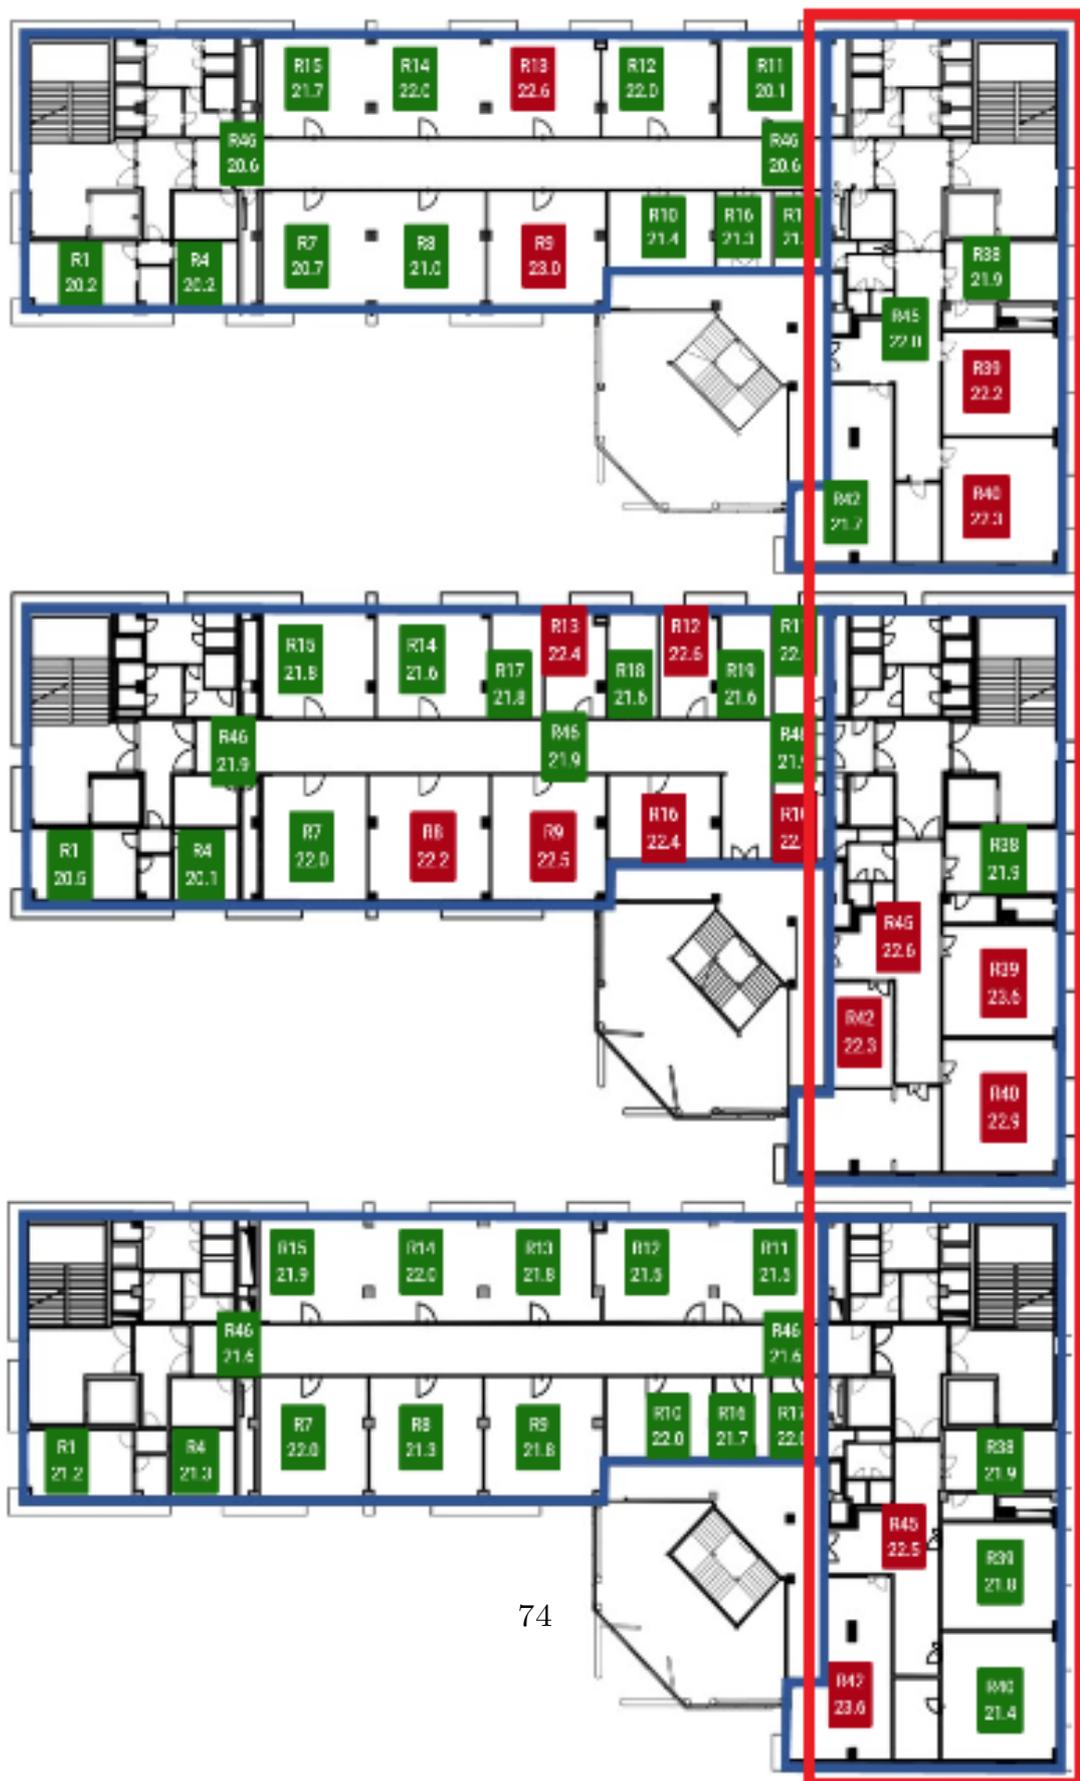


Figura 3.1: Planimetria dell'edificio di riferimento: dall'alto in basso, primo, secondo e terzo piano. La zona di riferimento è inclusa all'interno del rettangolo rosso

3.2 Data integration e data cleaning

In questa sezione vengono analizzate le diverse fonti che alimentano il contenuto informativo a disposizione, la natura dei dati e le operazioni effettuate per garantire una qualità accettabile dei dati in ingresso.

Il dataset finale è frutto di un'operazione di data integration riguardante diverse fonti:

- Una relativa alle misurazioni del grado di umidità e della temperatura del flusso d'aria in entrata e in uscita dagli impianti UTA degli interni della struttura;
- Una relativa alle misurazioni delle temperature di mandata e di ritorno riferite ai collettori freddo e caldo che alimentano i pannelli climatizzatori;
- Un'ultima relativa alle misurazioni delle temperature di setpoint e delle temperature ambiente nelle varie zone della struttura e della corrispondente temperatura esterna.

L'estensione temporale delle misurazioni per ogni fonte presentava dei contorni differenti, come si osserva in figura 3.1, cosicché il dataset finale ne risulta l'intersezione, in particolare la massima ampiezza che è stato possibile ottenere include le misurazioni dal 3 giugno 2019 al 14 maggio 2020, un intervallo di poco inferiore all'anno. La fase di data preprocessing ha incluso una fase di eliminazione dei

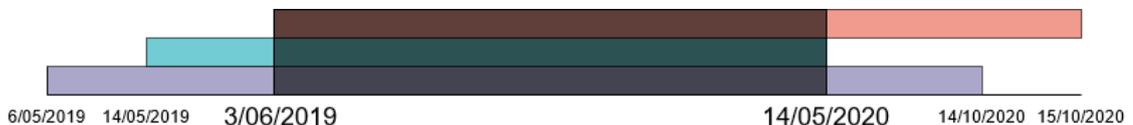


Figura 3.2: Rappresentazione dell'intervallo temporale di estensione del dataset al termine delle integrazioni a partire dalle varie fonti

duplicati e dei valori mancanti, considerati potenzialmente un ostacolo al buon funzionamento del modello. Se il numero dei duplicati in totale è risultato ridotto (solo 63 record), il numero dei valori mancanti era più considerevole, arrivando a 833 record. Trattandosi però esclusivamente di valori localizzati in un preciso intervallo di tempo, non c'è stata la possibilità di inferirli, una prassi comune nell'ambito del data mining per le serie di tempo. Si è optato quindi per la scelta obbligata di eliminarli dal dataset, nella speranza che il numero ridotto rispetto ai record totali (2,7%) non costituisse una perdita d'informazione decisiva per la predizione. Una così vasta finestra temporale comprendente esclusivamente dati mancanti può essere probabilmente imputata a un malfunzionamento congiunto dei sensori.

La procedura di intersezione sulla base della variabile temporale ha poi portato

un'ulteriore perdita di record, escludendo definitivamente quelli per cui non erano disponibili le informazioni su tutte le variabili di interesse. Si è successivamente applicato un filtro per dati rumorosi diversificato per feature. In particolare, per la temperatura esterna, sono state escluse temperature al di sotto del grado, in quanto le temperature nella zona climatica d'interesse non sono solite oltrepassare quella soglia. Per le temperature di mandata e ritorno dei collettori e di immissione e ripresa per le Unità di Trattamento Aria si è considerato un intervallo valido solo quello fra i 5 e i 70°C, per scongiurare qualsiasi cambiamento di fase dei fluidi così come temperature troppo estreme per l'Unità Trattamento Aria. Per lo stesso motivo, sono stati esclusi i record la cui percentuale di umidità superava una soglia critica. Le operazioni di filtraggio, riassunte nella tabella 3.2, hanno ridotto i record di soltanto 3 elementi, confermando una generale buona qualità delle misurazioni. Si deve comunque tenere presente, però, che si è trattato di una scrematura estremamente tollerante: questo perché i dati rumorosi non inficiano di solito in modo significativo le performance di modelli black-box come le reti neurali LSTM, quanto invece la scarsità di dati in input, circostanza che si è tentato di evitare.

Tabella 3.1: Tabella riepilogativa degli intervalli ritenuti accettabili per alcune feature, tradottisi nei filtri applicati per l'esclusione di eventuali dati rumorosi nella fase di datapreprocessing

Intervallo consentito	Feature
>1°C	Temperatura esterna
1-40°C	Temperature di setpoint e ambiente
5-70°C	Temperature di mandata e ritorno dei collettori
5-70°C	Temperature dell'aria di immissione e ripresa di UTA
5-95%	Umidità dell'aria di immissione e ripresa di UTA

3.3 Feature selection

In questa sezione, si descrive il processo di scrematura per le variabili ritenute non informative per la predizione delle variabili target, eliminate in quanto la loro presenza aggiungerebbe soltanto complessità al modello.

La delicata operazione di feature selection è stata condotta sulla base di una sola

Tabella 3.2: Riepilogo delle feature mantenute in seguito all'operazione di feature selection. (*) In totale il dataset include 5 temperature di setpoint e 5 temperature ambiente per ogni piano, relative per ogni piano a tutti gli uffici della manica corta, codificati come R-38, R-39, R-40, R-42, R-45.

Codifica feature	Descrizione	Unità di misura
TMandSoffitto	Si tratta della temperatura finale di mandata per i pannelli climatizzatori applicati al soffitto, le uniche fonti di climatizzazione per quanto riguarda le zone di interesse	°C
TRitCollFreddo	Si tratta della temperatura di ritorno del collettore freddo che alimenta i pannelli climatizzatori	°C
TMandCollFreddo	Si tratta della temperatura di mandata del collettore freddo che alimenta i pannelli climatizzatori	°C
TMandLatoBUTA	Si tratta della temperatura di mandata dell'Unità Trattamento Aria per quanto riguarda il lato B della struttura (la manica corta, la zona globale di interesse)	°C
TMandCollCaldo	Si tratta della temperatura di mandata del collettore caldo che alimenta i pannelli climatizzatori	°C
TRitCollCaldo	Si tratta della temperatura di ritorno del collettore caldo che alimenta i pannelli climatizzatori	°C
$U_{Mandata}^{*°P}$	Si tratta del grado di umidità di mandata dell'Unità di Trattamento Aria del piano di riferimento	int
$U_{Ripresa}^{*°P}$	Si tratta del grado di umidità di mandata dell'Unità di Trattamento Aria del piano di riferimento	int
$T_{Mandata}^{*°P}$	Si tratta della temperatura di mandata dell'Unità di Trattamento Aria del piano di riferimento	°C
$T_{Ripresa}^{*°P}$	Si tratta della temperatura di ripresa dell'Unità di Trattamento Aria del piano di riferimento	°C
$T_{esterna}$	Si tratta della temperatura registrata esternamente alla struttura	°C
$T_{setpoint}$	Si tratta della temperatura di setpoint impostata all'interno della zona(*)	°C
$T_{Ambiente}$	Si tratta della temperatura ambiente registrata all'interno della zona(*)	°C

relative al lato A dell'edificio, dove si trovano gli uffici di manica lunga, non oggetto di interesse, così come le variabili misurate relativamente ai pannelli localizzati sul pavimento e ai radiatori a parete, che non sono mezzi di climatizzazione utilizzati negli uffici di interesse.

3.4 Feature creation

In questa sezione, si motiva la scelta di introdurre una feature non presente originalmente nel dataset, ossia l'ora del giorno. Più in particolare, si è trattato di un'operazione di feature construction, che ha portato dunque alla creazione di una variabile non presente originariamente sulla base di informazioni incluse nelle feature fornite. La feature "Ora del giorno", infatti, deriva dalla feature originaria che includeva l'informazione temporale di ogni misurazione, utilizzata come chiave primaria per il join durante la procedura di data integration e poi adibita a indice del dataset. A partire da essa, era possibile estrarre non solo l'ora del giorno, ma anche il giorno dell'anno, così come il mese dell'anno e l'anno. Si è mantenuta soltanto l'ora del giorno, per non aumentare eccessivamente la dimensione in prima istanza, in secondo luogo perché ritenuta fortemente correlata alla temperatura misurata negli ambienti interni in quanto in grado di influenzare la temperatura esterna secondo un pattern riconoscibile. Sono stati ritenuti superflui il giorno dell'anno e il mese dell'anno, in quanto, come si osserva nella sezione successiva, esiste una notevole variabilità difficilmente riconducibile a questi attributi. Inoltre, il dataset è circoscritto a un periodo inferiore all'anno: potrebbe essere dunque impossibile identificare l'eventuale ruolo di uno di questi attributi, dal momento che non sarebbe possibile verificare uno o più trend a essi legati.

3.5 Data exploration

Questa sezione ha la finalità di concludere il capitolo, mediante un'esplorazione del dataset portata a compimento rappresentando l'andamento delle variabili, per identificare così altri possibili dati rumorosi. Il plot delle variabili è riportato nelle seguenti figure: 3.5, 3.6, 3.7, 3.8, 3.9, 3.10.

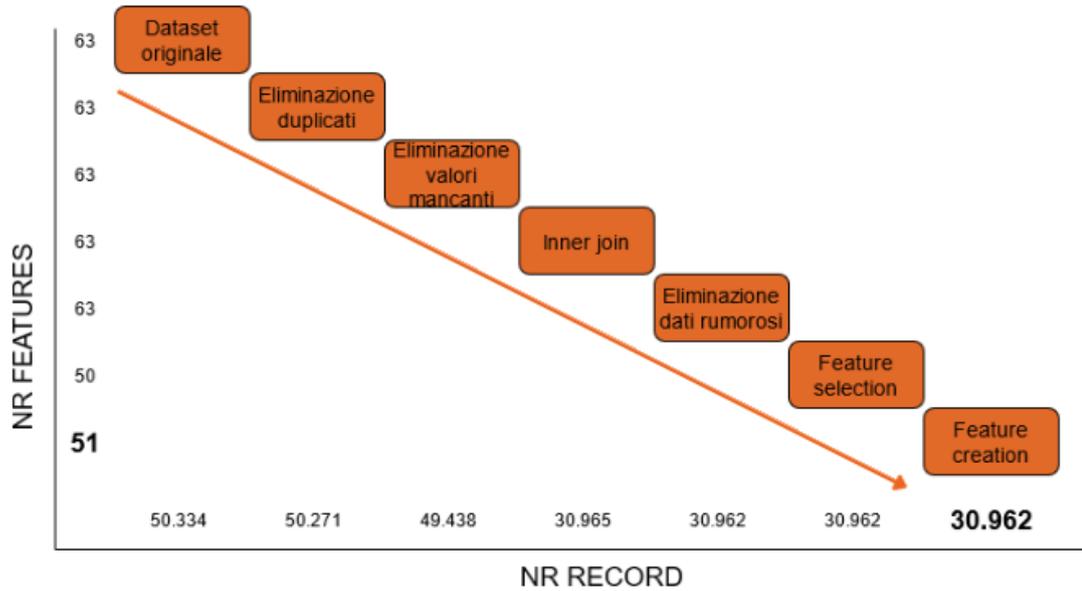


Figura 3.4: Schematizzazione delle varie fasi di data preprocessing, con l'indicazione dell'effetto sulla dimensione e sulla numerosità del dataset

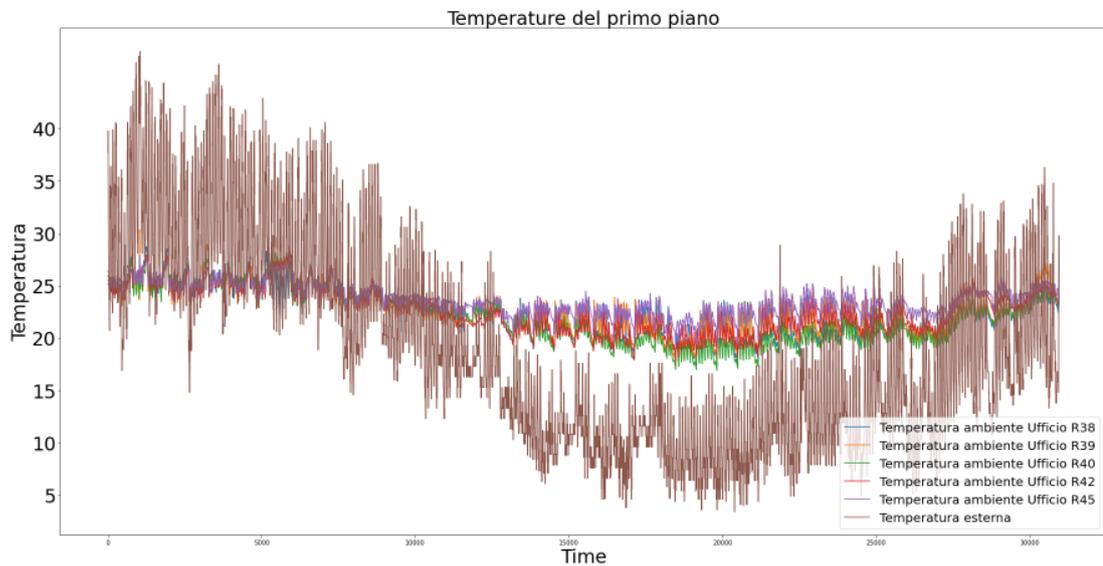


Figura 3.5: Andamento delle temperature ambiente del primo piano in funzione del tempo

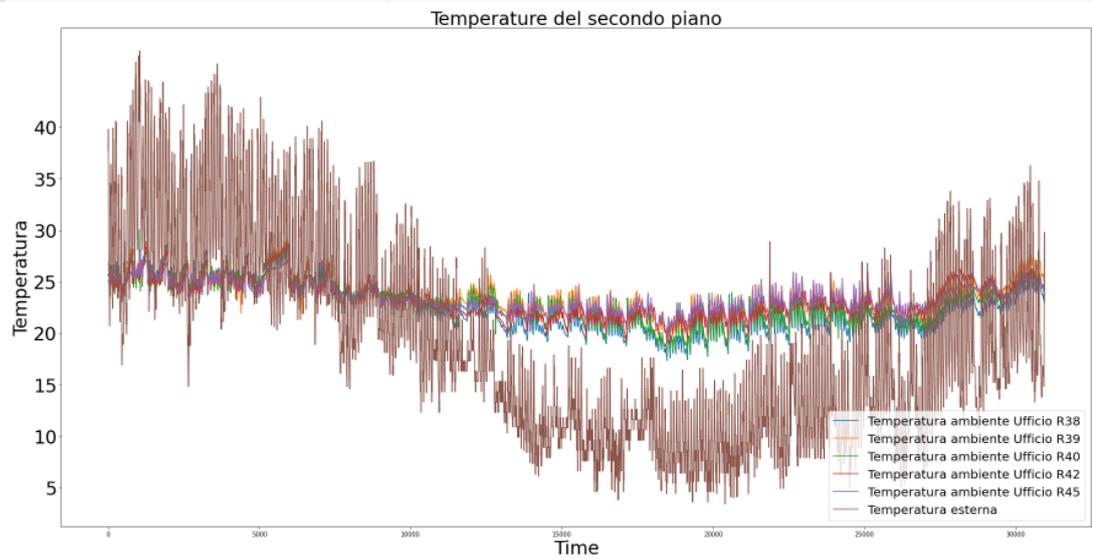


Figura 3.6: Andamento delle temperature ambiente del secondo piano in funzione del tempo

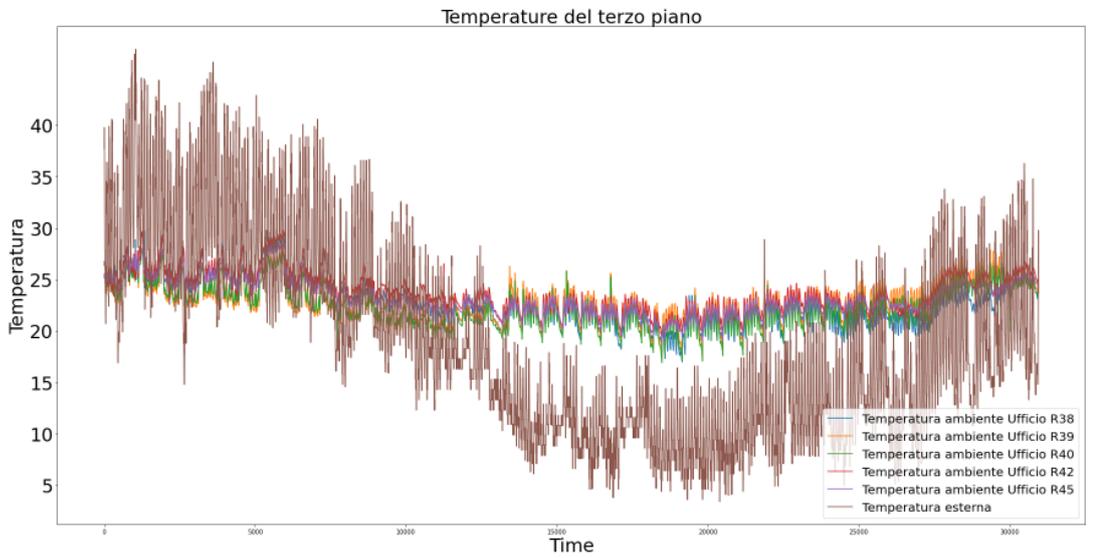


Figura 3.7: Andamento delle temperature ambiente del terzo piano in funzione del tempo

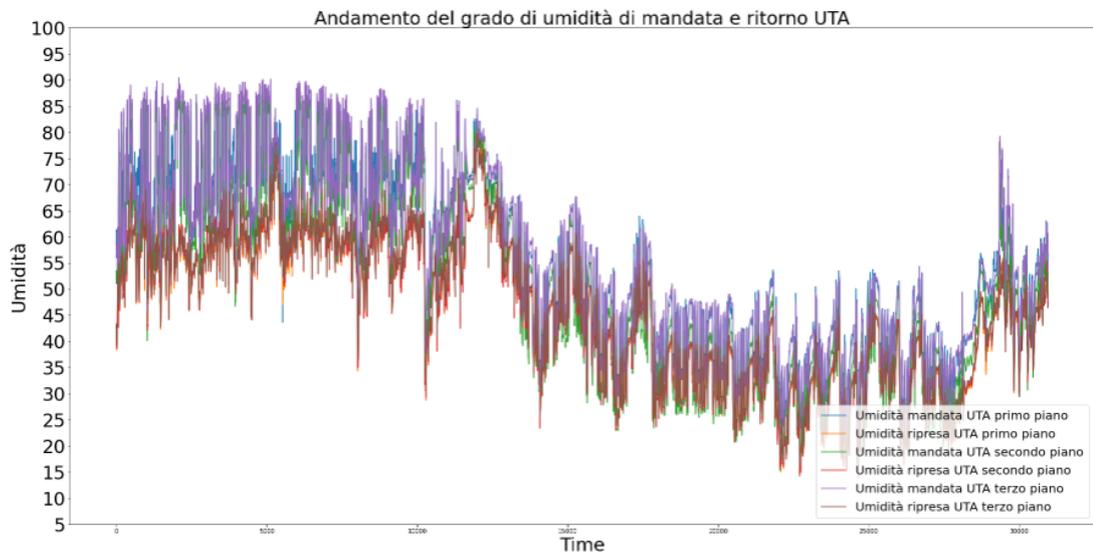


Figura 3.8: Andamento del grado di umidità di mandata e di ritorno UTA in funzione del tempo

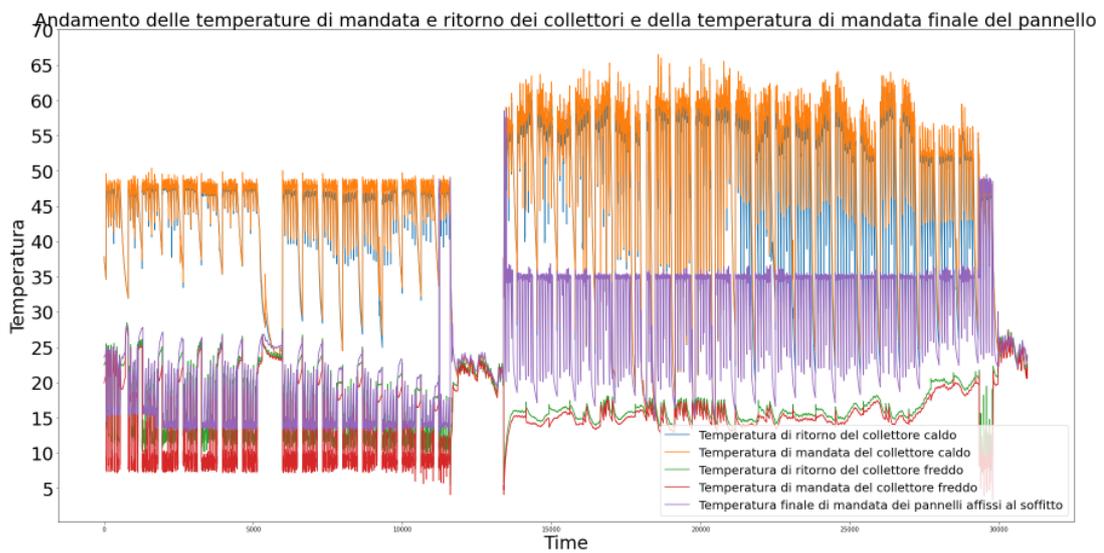


Figura 3.9: Andamento delle temperature di mandata e di ritorno dei collettori e della temperatura di mandata finale del pannello in funzione del tempo

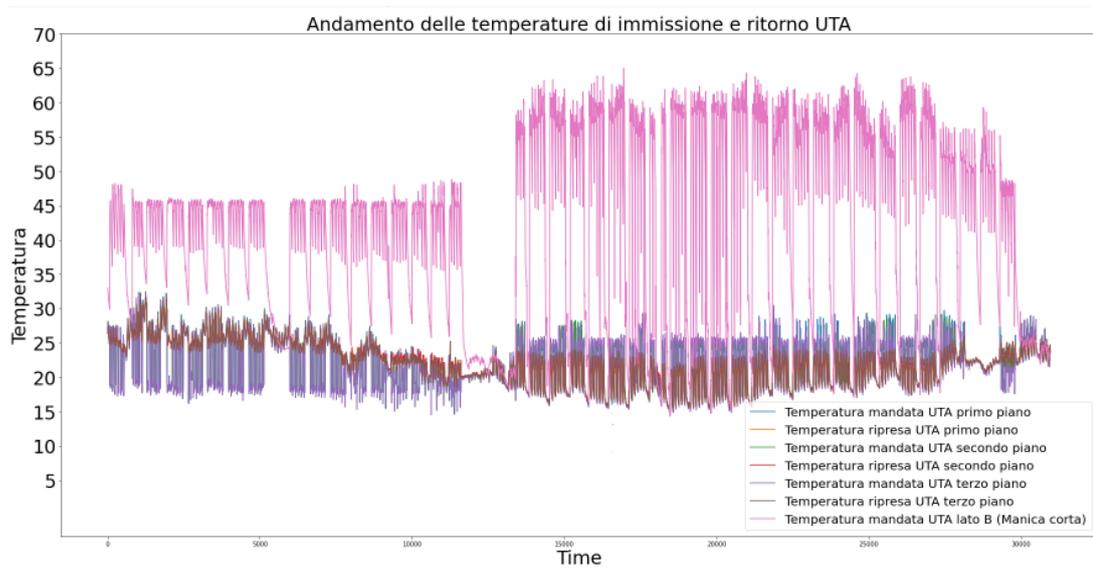


Figura 3.10: Andamento delle temperature di immissione e ritorno UTA in funzione del tempo

Se la maggior parte delle variabili sembra conservare un andamento entro limiti del tutto plausibili, viene invece identificata una fascia di possibili valori rumorosi, per quanto riguarda le misurazioni della temperatura esterna all'inizio della serie di tempo, dunque misurazioni attribuibili all'estate 2019, un'estate che, benché ricordata come particolarmente calda e afosa, difficilmente nella zona di Torino può aver condotto a picchi di temperature oltre i 45°C. Si è però deciso di mantenere tali record, per non rischiare di perdere troppa informazione e tenendo in considerazione che nella maggior parte dei casi modelli black-box come le reti neurali artificiali LSTM non sono particolarmente sensibili ad outlier e dati rumorosi. Per lo stesso motivo, si è evitato di identificare eventuali outlier tramite algoritmi come il DB Scan.

Capitolo 4

Implementazione dei modelli

In questo capitolo, viene dettagliata la definizione e la calibrazione dei modelli, in ottica MISO e MIMO, che restituiscano predizioni con un anticipo di 2 ore, 5 ore e 24 ore.

L'implementazione è stata resa possibile grazie all'utilizzo della libreria Keras.

4.1 Approccio

Come già anticipato in precedenza, il problema della predizione della temperatura interna agli edifici può rivelarsi notevolmente complesso e può essere affrontato seguendo due diversi approcci. Se la complessità dell'edificio da monitorare aumenta, infatti, esso deve essere decomposto fisicamente in zone, identificate come singole stanze o aree delimitate dell'edificio, a cui attribuire specifiche misurazioni di attributi. A questo punto, è possibile adottare un approccio MIMO o un approccio MISO. Il primo caso modella uno scenario più complesso: al modello vengono forniti in input tutti gli storici degli attributi associati a ciascuna zona diversa, ed è in grado di restituire in output variabili associate a una o più zone dell'edificio. Il sistema MISO, invece, consente un unico output, che può quindi riferirsi a una sola zona: ciò non significa, però, che la zona debba necessariamente essere trattata indipendentemente dalle zone adiacenti, trascurando i fenomeni di scambio di calore tra esse. In input, infatti, anche nei sistemi MISO, è possibile inserire variabili provenienti da una o più zone adiacenti o meno, o in qualche modo zone che si stima abbiano influenza nella determinazione della variabile di output della zona di interesse. La scelta di trattare ogni zona in modo separato è estremamente semplificativa e, benchè talvolta adottata, non sempre garantisce la massima accuracy; in questi casi, si tende a generare il risultato aggregato tramite

una media ponderata sul volume o sull'area delle zone coinvolte.

In questo studio, è stato ritenuto opportuno affrontare lo stesso problema su entrambi i piani, per cui nelle sezioni successive vengono dettagliati i risultati sia sperimentando un approccio MISO che un approccio MIMO, soprattutto con l'intenzione di individuare eventuali discrepanze che condizionano il risultato in funzione dell'approccio scelto. Nella tabella 4.1 sono riportati i ruoli assunti dalle variabili per ciascun approccio: la metodologia MIMO restituisce i valori di temperatura indoor per tutti gli uffici, mentre, a titolo puramente esemplificativo, la versione MISO predice soltanto la variabile riferita all'ufficio R40.

Tabella 4.1: Riepilogo del ruolo delle variabili per gli approcci MISO e MIMO

Variabili in input	Variabile target MISO	Variabili target MIMO
<ul style="list-style-type: none"> • Temperatura esterna • Temperature ambiente e di setpoint degli uffici del piano di riferimento • Temperature e umidità delle UTA del piano di riferimento • Temperature di mandata e di ritorno del collettore caldo e freddo e dei pannelli a soffitto 	<ul style="list-style-type: none"> • Temperatura ambiente dell'ufficio R40 del piano di riferimento 	<ul style="list-style-type: none"> • Temperature ambiente di tutti gli uffici del piano di riferimento

4.2 Definizione del modello

L'obiettivo di questo capitolo è identificare un modello adeguato per la predizione delle temperature ambiente sulla base delle feature individuate come influenti per questo fine nel corso del capitolo antecedente.

4.2.1 Architettura del modello

In questa sezione si introducono gli elementi componenti del modello finale riconducibili alla sua struttura. Il modello è costituito da un layer di input, uno di output, e un arbitrario numero di hidden layer intermedi. A ogni layer deve essere attribuita una specifica funzione di attivazione. Alcune varianti che verranno proposte per formulare l'architettura finale sono l'aggiunta di layer per dropout e di batch normalization; inoltre, verrà anche presa in considerazione un'architettura di tipo bidirezionale. I seguenti elementi vengono introdotti nei paragrafi successivi.

Elementi

LSTM Nel campo del deep learning, Long Short Term Memory è una tipologia di RNN sviluppata con il fine di oltrepassare la criticità del vanishing gradient. E' una tipologia in grado di processare non solo data point singoli, ma anche intere sequenze di dati e per questo particolarmente utilizzata nel campo della predizione di serie storiche.

LSTM bidirezionale La versione bidirezionale è un'estensione della versione tradizionale, che include la duplicazione del primo layer in modo da ottenere due layer affiancati; dopodiché al primo strato verrà proposta la sequenza di input originale, mentre al secondo verrà fornita la stessa sequenza ma all'inverso. Dunque, è una struttura pensata per superare i limiti della struttura regolare, riuscendo a utilizzare le informazioni in input disponibili sia nel passato che nel futuro per uno specifico time frame, delegando a una metà dello strato tradizionale la responsabilità per la direzione temporale positiva e all'altra metà quella per la direzione temporale negativa.

Secondo la documentazione di Keras [43], la libreria non solo consente di specificare la numerosità del layer, ma anche le modalità di merge tra i due layer affiancati. La modalità di default prevede la concatenazione, ed è questa la modalità utilizzata nelle prove successive.

Regolarizzazioni

Dropout Dropout è una tecnica di regolarizzazione per le reti neurali, proposta da Srivastava, et al. [44], nel 2014. Il funzionamento consiste nell'ignorare durante

la fase di training un subset di neuroni selezionati in modo casuale: essi vengono metaforicamente “dropped-out” e il loro contributo viene momentaneamente annullato, dunque i relativi pesi non vengono aggiornati. Poiché i pesi dei neuroni si stabilizzano in base alle feature, influenzando anche i neuroni adiacenti successivamente, eliminare il ruolo di alcuni neuroni durante alcune fasi dell’allenamento consente ai restanti di apprendere in modo indipendente ed evita così un’eccessiva specializzazione che renderebbe il modello fragile e privo di capacità di generalizzare. Si tratta, infatti, di una regolarizzazione utilizzata spesso per prevenire una situazione di overfitting. In questo contesto, la regolarizzazione Dropout è implementata sfruttando la libreria Keras, dove è necessario inserire la probabilità di esclusione a cui i neuroni sono sottoposti relativamente a ogni ciclo di aggiornamento dei pesi.

Funzione di attivazione

La funzione di attivazione viene specificata per ciascun layer e ha il ruolo di identificare quali neuroni escludere, impedendo alle connessioni adiacenti di venirne influenzate, in funzione dell’output da essi prodotto. Le funzioni di attivazione si differenziano l’un l’altra sulla base dei criteri adottati per l’estromissione del neurone generatore dell’output valutato.

In questa sede, la funzione di attivazione utilizzata per tutti i layer ad eccezione dell’ultimo è la funzione ReLU (rectified linear activation function), che restituisce l’output se positivo, altrimenti restituisce un valore nullo. E’ stata scelta per via della sua versatilità, per la sua capacità di aggirare l’annoso ostacolo del vanishing gradient e perché permette al modello di apprendere in modo rapido, grazie alla sua semplicità computazionale che implica l’applicazione di una funzione massimo. E’, inoltre, in grado di restituire valori nulli a differenza di altre funzioni che tendono soltanto ad avvicinarsi a questa soglia, riuscendo di fatto a creare una sparsità di neuroni che può rivelarsi efficace nell’apprendimento.

L’ultimo layer, invece, viene dotato di una funzione di attivazione lineare, in modo da restituire l’output finale risultante dall’apprendimento. Il numero di neuroni di questo layer conclusivo, nell’ottica di una best practice piuttosto diffusa nella letteratura, è pari al numero di output previsti, quindi 1 nel caso dei modelli per quanto riguarda l’approccio Single Output, 5 nel caso dei modelli nel contesto dell’approccio Multi Output.

4.2.2 Training del modello

Funzione di loss Le funzioni di loss vengono specificate durante la compilazione del modello Keras con l’obiettivo di indicare al modello la metrica che il modello deve cercare di minimizzare durante il training. In questa sede, vengono utilizzate:

- La metrica MAE (Mean Absolute Error), che calcola l'errore di predizione effettuando la somma delle differenze tra i valori predetti e quelli effettivi e poi divide questo risultato per il numero di campioni, in modo da ottenere un risultato medio (equazione 4.1).
- La metrica MSE (Mean Squared Error), che identifica invece la bontà delle predizioni sommando gli scostamenti al quadrato tra valori predetti e reali, così da eliminare il contributo dei segni, ed effettua nuovamente la media finale (equazione 4.2).

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (4.1)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \tilde{y}_i)^2 \quad (4.2)$$

Optimizer L'ottimizzatore è uno dei parametri necessari per permettere a un modello Keras di compilare. Infatti, consente di individuare i pesi all'interno dell'architettura del modello che consentono di individuare il minimo della funzione di perdita specificata, così da rendere il più possibile le predizioni accurate. Gli optimizer presi in considerazione sono tre fra i più utilizzati in letteratura con finalità di regressione:

- SGD (Stochastic Gradient Descent): si basa sul calcolo del gradiente, ossia la differenza che un cambiamento nei pesi produce nella funzione di loss, e continua ad aggiustare i pesi finchè non è più possibile ottenere un gradiente in discesa.
- Adagrad (Adaptive gradient algorithm): il suo principio di funzionamento permette di adattare il learning rate a ciascuna feature, quindi i pesi nell'architettura finale non sempre vengono individuati con un learning rate coincidente. nuovamente la media finale.
- Adam (Adaptive moment estimation): è a sua volta in grado di variare il proprio learning rate, ma non sulla base della media del gradiente come ad esempio vale per RMSProp, ma sulla base della varianza. Si tratta di un ottimizzatore a cui è universalmente riconosciuto il merito, inoltre, di giungere più rapidamente a convergenza.

4.3 Test e risultati

4.3.1 Suddivisione in training, test e validation set

In questa sezione vengono esposte le modalità di creazione di un dataset per la validazione, oltre che per il testing. Come è prassi, il modello non viene solamente testato sulla parte del dataset originale non utilizzata per il training, ma anche su una porzione di dati non precedentemente elaborati. Questo step aggiuntivo, qui definito validazione, è necessario per verificare ulteriormente la bontà delle predizioni del modello. Dal momento che ogni modello si riferisce ad un solo specifico piano, sarà necessario effettuare la suddivisione in training set, test set e validation set per ogni porzione di dataset riferita a ciascun piano, utilizzando un criterio che prevede poco più del 70% dei dati destinati al training, e il restante 30% suddiviso a metà fra test set e validation set. Nella tabella 4.2 è possibile osservare un riepilogo della suddivisione del dataset nelle tre porzioni necessarie.

Tabella 4.2: Riepilogo della suddivisione in training, test e validation set in termini di quota sul totale e intervallo temporale

Dataset	Quote sul totale	Arco temporale
Training set	Circa 70%	8 mesi
Test set	Circa 15%	1,5 mesi
Validation set	Circa 15%	1,5 mesi

4.3.2 Metriche di performance

Le metriche utilizzate per misurare la performance dei modelli sono state principalmente due.

- RMSE (Root Mean Squared Error) (equazione 4.3): si tratta di una metrica comune nel quantificare le differenze fra i valori predetti e quelli reali. E' una metrica di accuracy, in grado di aggregare la mole degli errori di predizione per vari time step nei riguardi della variabile d'interesse e fornire così un'indicazione del potere di predizione, tanto più alto quanto più l'indicatore ha un valore contenuto. La normalizzazione può essere d'aiuto nel caso di confronti fra dataset o modelli con scale non paragonabili. L'errore quadratico medio può essere espresso sotto radice o meno, in quest'ultimo caso esprime a sua volta la qualità del predittore, ma l'uso di questa metrica risulta particolarmente importante quando ad eventuali vasti errori sia necessario attribuire un peso, poiché il quadrato, in presenza di errori di questo genere, provoca un rialzo notevole e di conseguenza un significativo peggioramento dell'indicatore.

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (\hat{y}_i - y_i)^2}{N}} \quad (4.3)$$

- MAE (Mean Absolute Error) (equazione 4.1): è una metrica di distanza che quantifica la somma delle differenze (sempre positive, per via del valore assoluto) fra il valore predetto e quello effettivo. E' una metrica molto robusta agli outlier e al rumore, ed è inoltre facilmente interpretabile.

Inoltre, in alcune occasioni si è comunque tenuto conto di un ultimo aspetto, il tempo d'iterazione. Si tratta, infatti, di un aspetto da non sottovalutare, e se breve costituisce un notevole punto di forza, in quanto la maneggevolezza dei modelli è un feature irrinunciabile per una loro fruizione nel settore.

4.3.3 Approccio MISO

Nei prossimi paragrafi, verranno mostrati e commentati i risultati di alcuni esperimenti in cui si variano i parametri del modello con l'obiettivo di identificare i valori delle variabili che rendono il modello più performante. L'obiettivo primario è selezionare i modelli in grado di evitare il fenomeno dell'overfitting, quindi in grado di ottenere un errore il più basso possibile e il più possibile omogeneo tra le diverse sezioni del dataset.

- Della complessità del modello, variando il numero di neuroni per ogni layer del modello;

- Della presenza della regolarizzazione effettuata tramite inserimento di una probabilità di dropout;
- Del valore di learning rate prescelto;
- Dell'ampiezza dell'orizzonte di predizione.

Rispetto alla trattazione seguente riguardante l'approccio Multi Output, le prove riportate in questa sede sono molto meno numerose, per comodità. Infatti, poiché l'approccio Multi Output è in grado di restituire tutti i valori delle variabili target ed è a tutti gli effetti il focus dell'analisi, è stato ritenuto opportuno evitare ogni ridondanza e dettagliare maggiormente la sezione ad esso dedicata.

Costanti

Gli esperimenti vengono portati a compimento e l'alternativa migliore viene individuata a parità di alcuni parametri che vengono fissati a priori e mai modificati quali il numero di epoche di allenamento (fissato a 100) e la dimensione del batch size (fissato al valore convenzionale 64). Queste scelte vengono mantenute anche nel corso degli esperimenti relativi all'approccio MIMO, trattato successivamente.

Influenza della complessità del modello

In questo paragrafo vengono mostrate le performance per quanto riguarda le predizioni dei valori del test set e dei due validation set al variare della complessità del modello. La complessità si declina non solo come numero di layer del modello, ma anche in rapporto al numero di neuroni che popolano ogni layer del modello. Le prove prevedono un aumento del numero di neuroni per layer (ad eccezione, ovviamente, del layer di output, il cui numero di neuroni è sempre fissato a 1) dal numero di 64 al numero di 256, passando per lo step intermedio di 128. Vengono arbitrariamente utilizzati come optimizer Adam e come funzione di loss MSE. L'allenamento si protrae per 100 epoche.

Risulta che la crescente numerosità di neuroni per layer ha l'effetto di abbassare, con un andamento quasi lineare, l'ammontare dell'errore sul test set e sul validation set per il primo piano (figura 4.1). Se in questo caso la scelta migliore risulta palesemente il modello più complesso, non è altrettanto scontato per quanto riguarda le altre due porzioni di dataset. Sia per il secondo che per il terzo piano, infatti, la numerosità maggiore sembra condurre a una possibile situazione di overfitting: infatti si nota come l'errore sul test set continua a scendere, mentre quello sul validation set sale rispetto alla prestazione del modello precedente (figure 4.2 e 4.3). Per il secondo piano lo scostamento è piuttosto significativo al punto che si è ritenuto opportuno preferire il modello con numerosità 128, che, inoltre, garantisce

un errore medio più contenuto. Le predizioni sul terzo piano, invece, si rivelano accettabili anche con il modello con massima numerosità, scegliendo anche questa volta in base all'errore medio. Nel complesso, dunque, l'errore misurato con la metrica RMSE rimane nell'ordine di 0.05 punti ed è pienamente accettabile.

ERRORE AL VARIARE DELLA NUMEROSITA' DEI LAYER - I PIANO

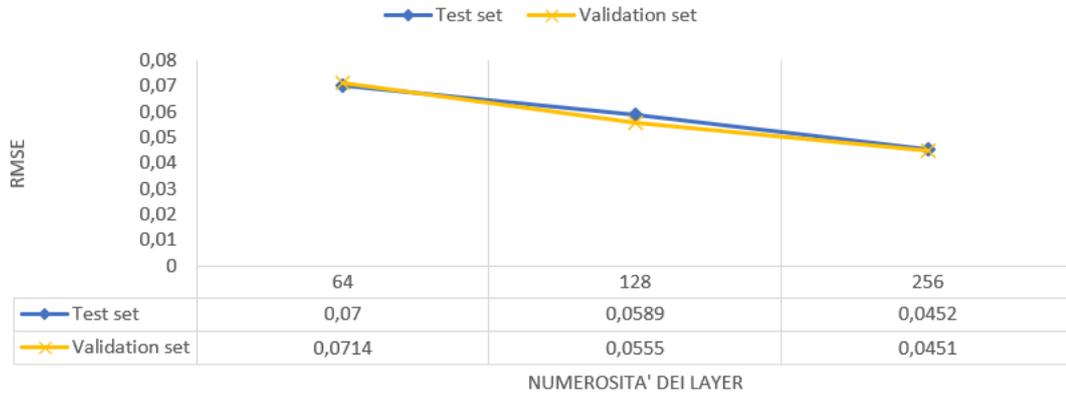


Figura 4.1: Errore in funzione della complessità del modello (numerosità dei layer) - I piano - Approccio MISO

ERRORE AL VARIARE DELLA NUMEROSITA' DEI LAYER - II PIANO

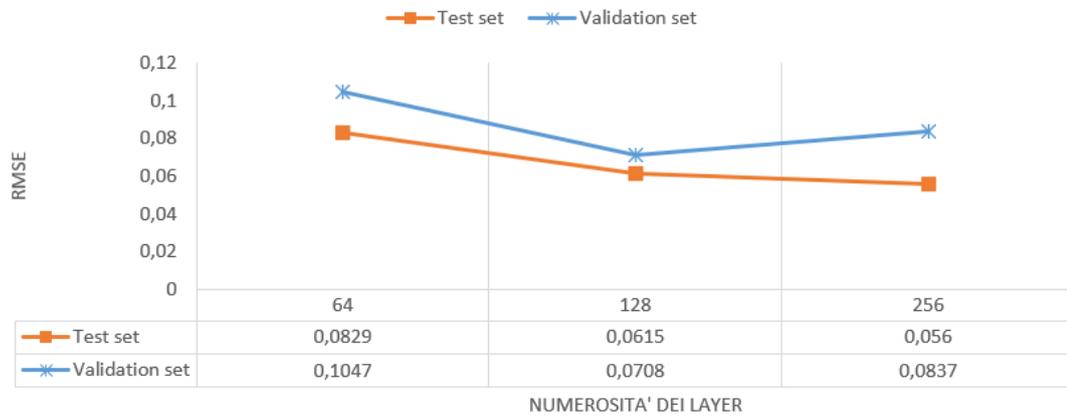


Figura 4.2: Errore in funzione della complessità del modello (numerosità dei layer) - II piano - Approccio MISO

ERRORE AL VARIARE DELLA NUMEROSITA' DEI LAYER - III PIANO

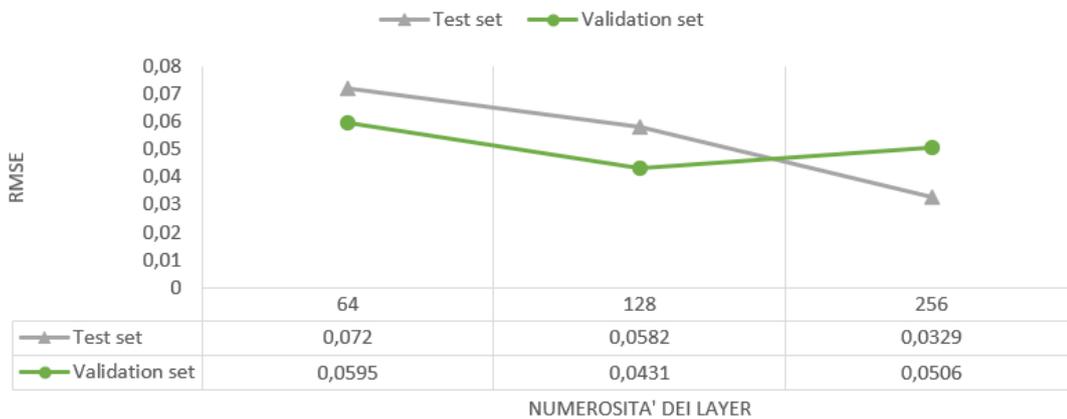


Figura 4.3: Errore in funzione della complessità del modello (numerosità dei layer) - III piano - Approccio MISO

Influenza del dropout

In questa sezione si sperimentano gli effetti della presenza di un layer di Dropout collocato subito dopo l'hidden layer presente. Se il modello attuale presentasse una tendenza all'overfitting, la presenza di un layer di dropout potrebbe limare questo comportamento. Gli esperimenti vengono effettuati sui modelli di numerosità 256, e non su quelli più semplici che sono privi della tendenza all'overfitting, applicando un dropout con una probabilità variabile tra il 20%, il 50% e il 70%, su 100 epoche di allenamento, utilizzando come optimizer Adam per garantire il minor tempo di convergenza e scegliendo come funzione di loss MSE.

Le prove mostrano che l'effetto di tale strato è quello di uniformare le prestazioni sul test set a quelle sul validation set, e quindi di ridurre la possibilità di overfitting. Si tratta di un andamento sistematico: è infatti possibile osservare tale trend per tutte le casistiche considerate (figure 4.4, 4.5, 4.6). D'altra parte, però, l'effetto della regolarizzazione non consiste soltanto nell'uniformare le prestazioni su test e validation set, ma anche nell'accrescere in modo costante l'errore, che nel caso più estremo sfiora e talvolta supera anche la soglia di 0.1 per RMSE, motivo per cui la feature del dropout non è stata inclusa nel modello.

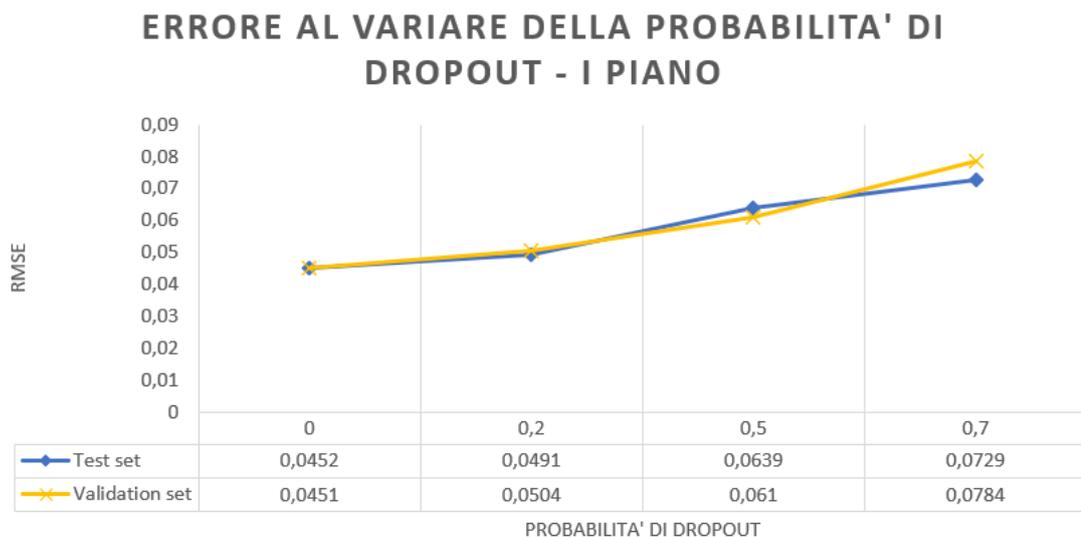


Figura 4.4: Errore al variare della probabilità di dropout - I piano - Approccio MISO

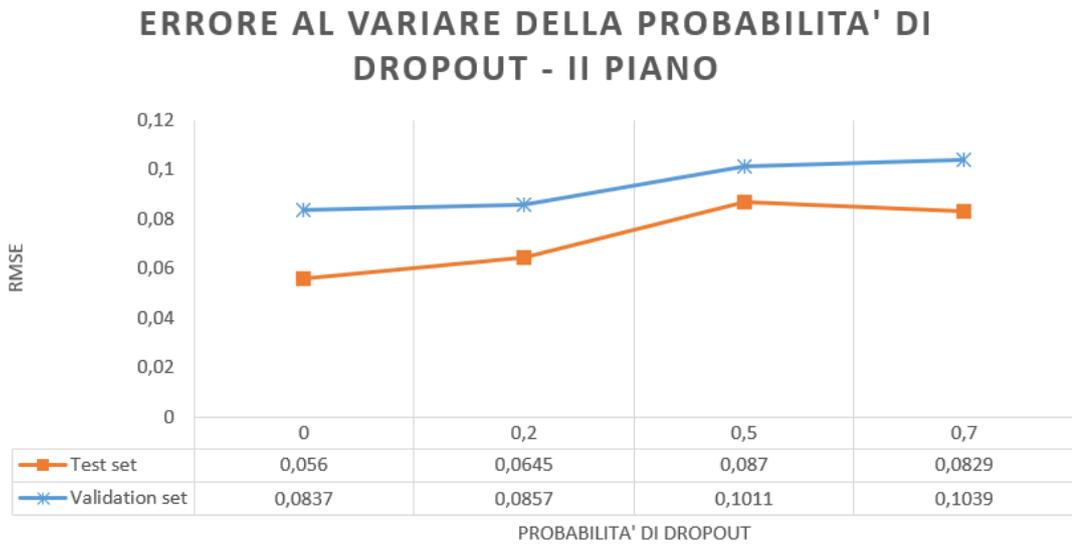


Figura 4.5: Errore al variare della probabilità di dropout - II piano - Approccio MISO

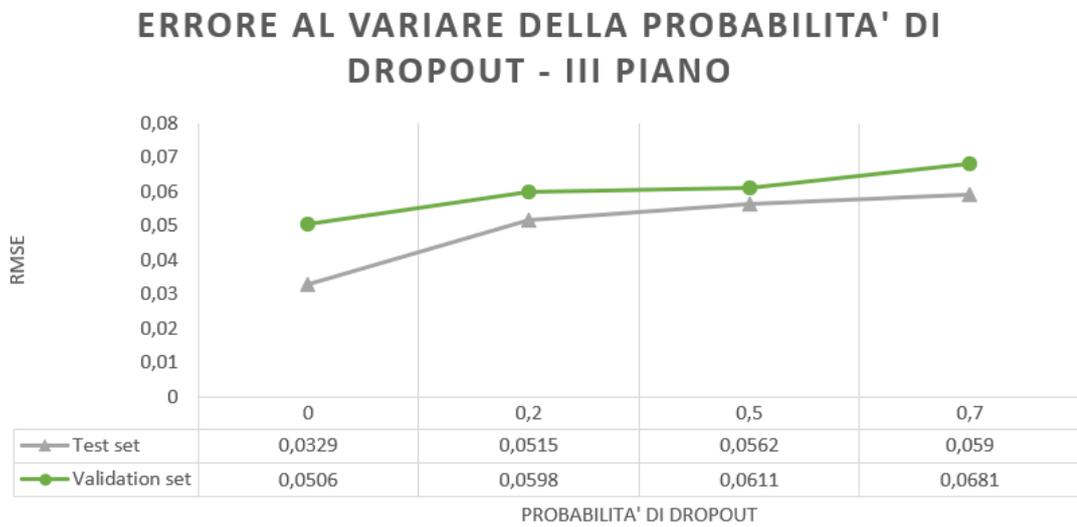


Figura 4.6: Errore al variare della probabilità di dropout - III piano - Approccio MISO

Influenza del learning rate

In questa sezione, si osserva l'effetto prodotto da un cambiamento del learning rate, uno dei parametri più impattanti sulle performance dei modelli. Il learning rate, come suggerisce il nome stesso, è la velocità con cui il modello apprende. Ad ogni iterazione, infatti, l'ottimizzatore modifica i pesi alla ricerca di un minimo nella funzione di loss, con una magnitudine proporzionale al learning rate impostato. L'individuazione di un learning rate ottimale pone di fronte a una situazione di trade-off, in quanto la scelta di un learning rate troppo alto potrebbe condurre al problema noto come oscillation performance, in cui il passo compiuto è troppo ampio e non permette di individuare il minimo della funzione; d'altro canto, un learning rate troppo basso potrebbe dilatare notevolmente i tempi di allenamento oltre a rischiare di individuare un minimo locale, e non assoluto, nella funzione obiettivo.

Le prove finora effettuate si sono basate su un learning rate di 0.000001. L'esperimento prevede di aumentare questo valore, scegliendo i successivi valori convenzionali di 0.00001, 0.0001, fino a raggiungere 0.001. Il numero di epoche di allenamento è fissato a 100 anche in questo caso, così come l'optimizer resta Adam e la funzione di loss è rappresentata dalla metrica MSE. Il learning rate utilizzato è quello che si è dimostrato più adeguato per la struttura del modello con 64 neuroni, pari a 0.000001. Osservando le loss function associate ai diversi learning rate testati, riportate in figura 4.7, si osserva l'andamento oscillatorio dell'errore sopra menzionato in funzione delle epoche di allenamento, un andamento che riguarda principalmente il test set, ma coinvolge, anche se in minima parte, il training set. La funzione tende a stabilizzarsi con il decrescere del learning rate, fino al valore di 0.000001, ritenuto il più accettabile. Sulla base dell'osservazione delle loss function, tenendo conto anche che i tempi di allenamento rimangono tutt'altro che proibitivi, il valore di 0.000001 viene mantenuto tale anche nella sezione dedicata all'approccio Multi Output.

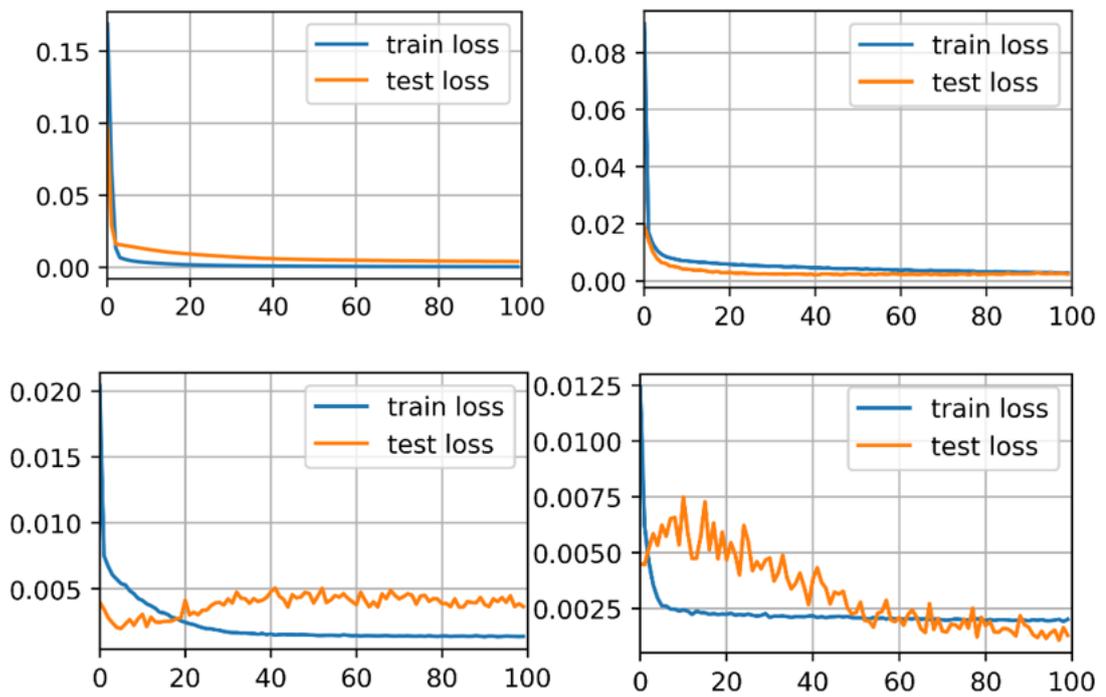


Figura 4.7: Loss curve al crescere del learning rate; da sinistra a destra: 0.000001, 0.00001, 0.0001, 0.001 - Approccio MISO

Influenza dell'ampiezza dell'orizzonte di predizione

Questa ultima sezione ha lo scopo di illustrare le performance del modello al variare dell'orizzonte di predizione, riuscendo così in ultima istanza a ricavare l'errore registrato sulle predizioni per ognuno degli orizzonti di predizione presi in considerazione.

I banchi di prova sono stati individuati con una predizione nell'ordine di:

- 2 ore (e.g. 8 time step);
- 5 ore (e.g. 20 time step);
- 24 ore (e.g. 96 time step).

Dai grafici sottostanti si evince che l'allungamento dell'orizzonte di predizione determina un lieve aumento dell'errore. Nel caso del secondo piano (figura 4.9), evidentemente caratterizzato da una maggiore complessità in quanto è proprio qui che si verifica sistematicamente l'errore di predizione più elevato, con una predizione nell'ordine delle 24 ore si arriva a oltrepassare la soglia di 0.09, nettamente distante rispetto alle altre due casistiche. Proprio per il secondo piano, infatti, per far fronte alla crescente complessità, è stato necessario ripiegare sulla struttura a 256 neuroni scartando la struttura a 128 utilizzata per gli intervalli di tempo di 2 ore e 5 ore. Essa consente, dunque, di raggiungere un errore medio inferiore, ma ricade in una situazione di overfitting, con un picco nell'errore sulla validazione, avvenimento che era stato parzialmente evitato con gli orizzonti di predizione più corti grazie all'utilizzo di un modello più semplice.

Il primo e il terzo piano, invece, presentano errori più contenuti e del tutto uniformi, caratterizzati da un lentissimo incremento in fase con la dilatazione dell'orizzonte (figure 4.8 e 4.10).

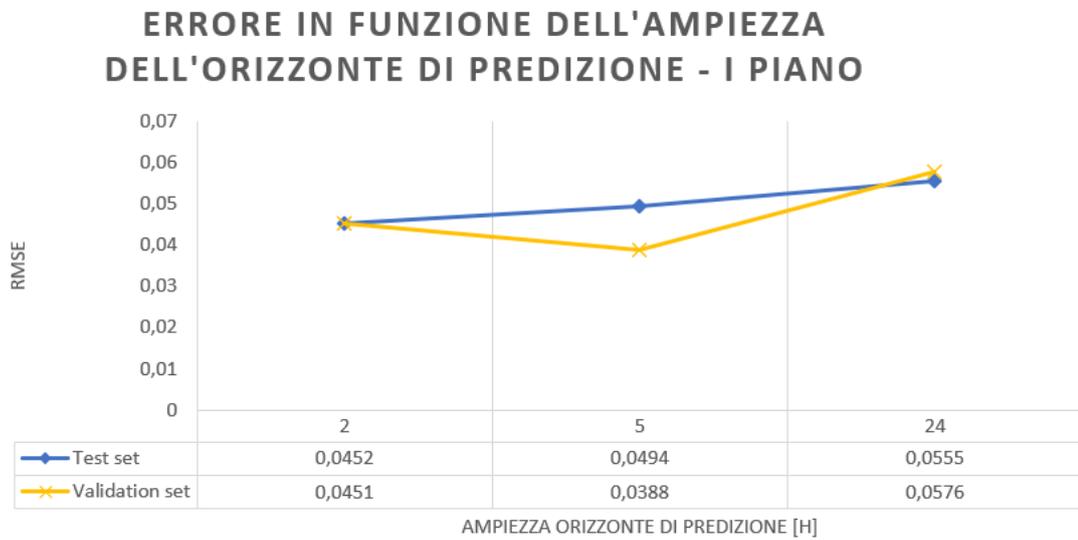


Figura 4.8: Errore in funzione dell'ampiezza dell'orizzonte di predizione - I piano - Approccio MISO

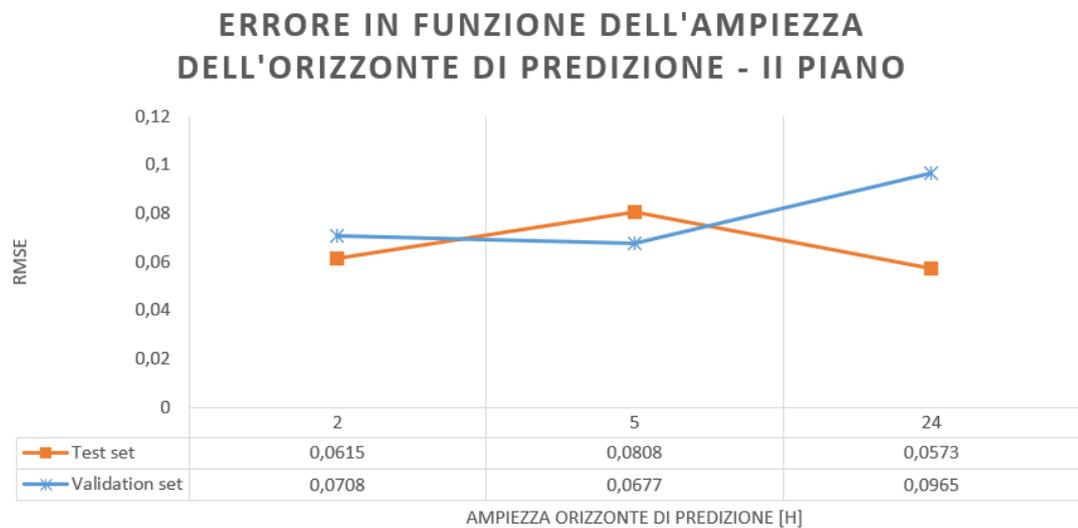


Figura 4.9: Errore in funzione dell'ampiezza dell'orizzonte di predizione - II piano - Approccio MISO

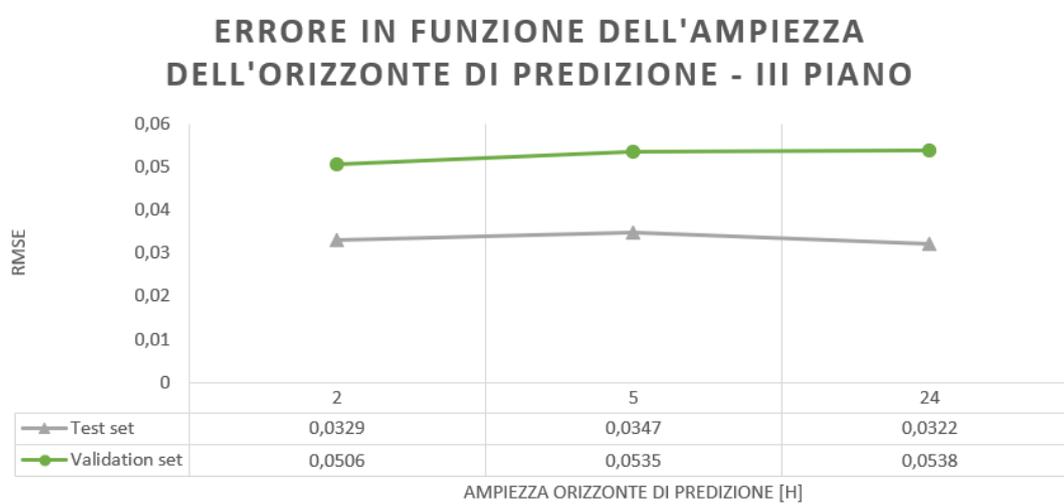


Figura 4.10: Errore in funzione dell'ampiezza dell'orizzonte di predizione - III piano - Approccio MISO

Viene di seguito riportata la tabella riepilogativa dei risultati ottenuti per quanto riguarda l'approccio Single Output (Tabella 4.3).

Tabella 4.3: Tabella riepilogativa dei risultati ottenuti - Approccio MISO

	RMSE					
	Primo piano		Secondo piano		Terzo piano	
	Test set P1-R40	Validation set P1-R40	Test set P1-R40	Validation set P1-R40	Test set P1-R40	Validation set P1-R40
2 ore	0,0452	0,0451	0,0615	0,0708	0,0329	0,0506
5 ore	0,0494	0,0388	0,0808	0,0677	0,0347	0,0535
24 ore	0,0555	0,0576	0,0573	0,0965	0,0322	0,0538

4.3.4 Approccio MIMO

Nella sezione successiva si riportano i risultati ottenuti utilizzando l'approccio MIMO, generalizzazione della versione adottata precedentemente. Tale approccio prevede di considerare come zona target un intero piano, all'interno del quale identificare le temperature ambiente per ciascuna stanza.

La calibrazione dei parametri è effettuata come nel caso dell'approccio precedente, utilizzando un'analisi basata sulle seguenti dimensioni:

- La complessità del modello;
- L'ammontare della probabilità di dropout;
- La struttura del modello - tradizionale o bidirezionale;
- La funzione di loss;
- L'optimizer;
- L'ampiezza dell'orizzonte di predizione.

Lo scopo della sezione è infatti determinare l'influenza di ciascuna variabile, a parità degli altri parametri, e identificare la combinazione più aderente alle necessità dello specifico dataset.

Costanti

Gli esperimenti vengono portati a compimento e l'alternativa migliore viene individuata a parità di alcuni parametri che vengono fissati a priori e mai modificati quali il numero di epoche di allenamento (fissato a 100) e la dimensione del batch size (fissato al valore convenzionale 64). Essi coincidono con quelli mantenuti costanti quando si è adottato l'approccio MISO.

Influenza della complessità del modello

In questa sezione vengono mostrate le performance per quanto riguarda le predizioni dei valori del test set e del validation set per ogni piano al variare della complessità del modello. La complessità si declina in rapporto al numero di neuroni che popolano ogni layer del modello.

Le prove prevedono un aumento del numero di neuroni per layer (ad eccezione, ovviamente, del layer di output, il cui numero di neuroni è sempre fissato a 5) dal numero di 64 al numero di 256, passando per lo stadio intermedio di 128. Vengono arbitrariamente utilizzati come optimizer Adam e come funzione di loss MSE. L'allenamento si protrae per 100 epoche.

Come si evince dai grafici sotto riportati (figure 4.11 - 4.16), l'ammontare dell'errore, sia medio che massimo, diminuisce all'aumentare della complessità del modello che consente una maggiore specializzazione sul dataset di allenamento. La ripidità della curva diminuisce con l'aumentare della complessità, rimandando a una forma quasi esponenziale. La numerosità di 256 si rivela senza dubbio la più adeguata per tutti e tre i piani, anche se le prestazioni migliori vengono raggiunte con il primo piano, dove l'errore medio si colloca fra un RMSE di 0.06 e 0.05 sia per il test set che per il validation set; per quanto riguarda gli altri due piani, invece, l'errore medio si attesta tra 0.07 e 0.08, mentre il massimo talvolta supera 0.1.

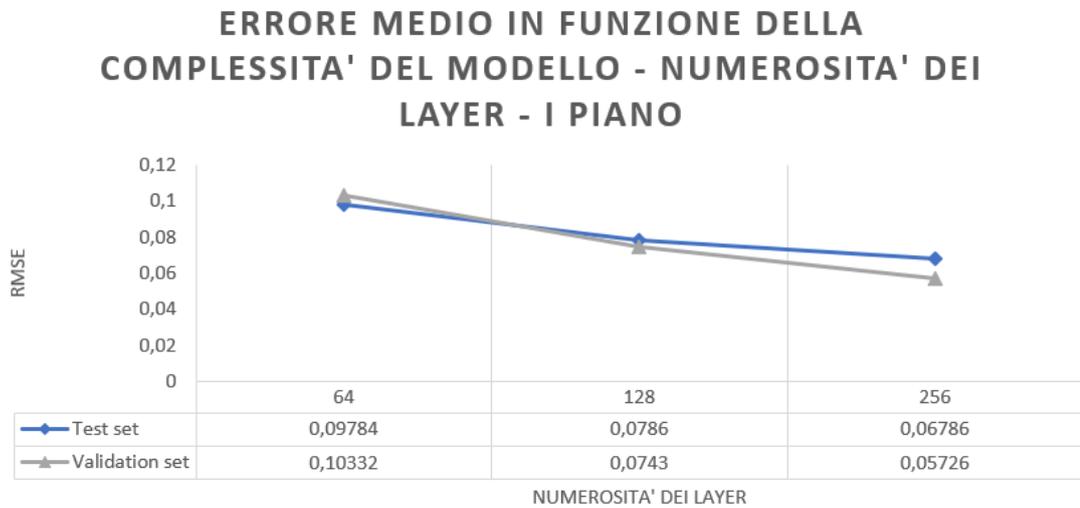


Figura 4.11: Errore medio in funzione della numerosità dei layer - I piano - Approccio MIMO

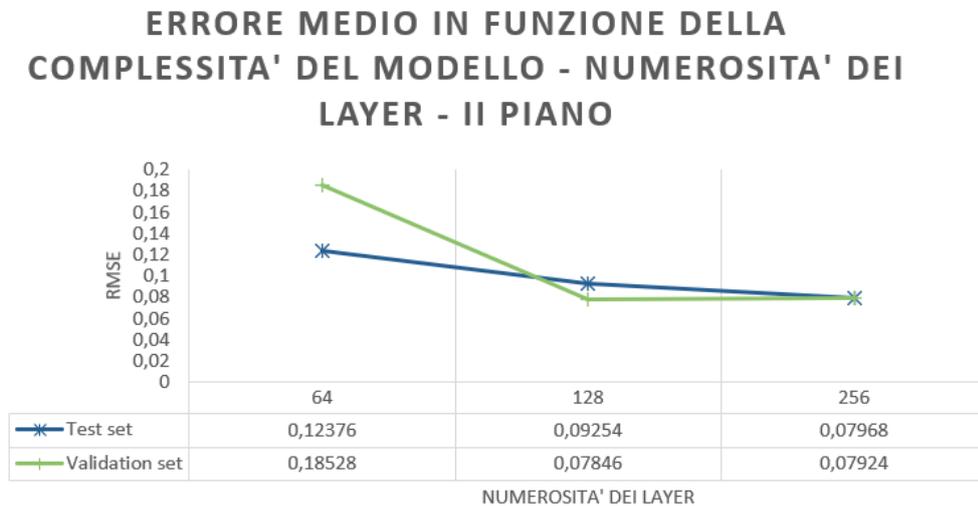


Figura 4.12: Errore medio in funzione della numerosità dei layer - II piano - Approccio MIMO

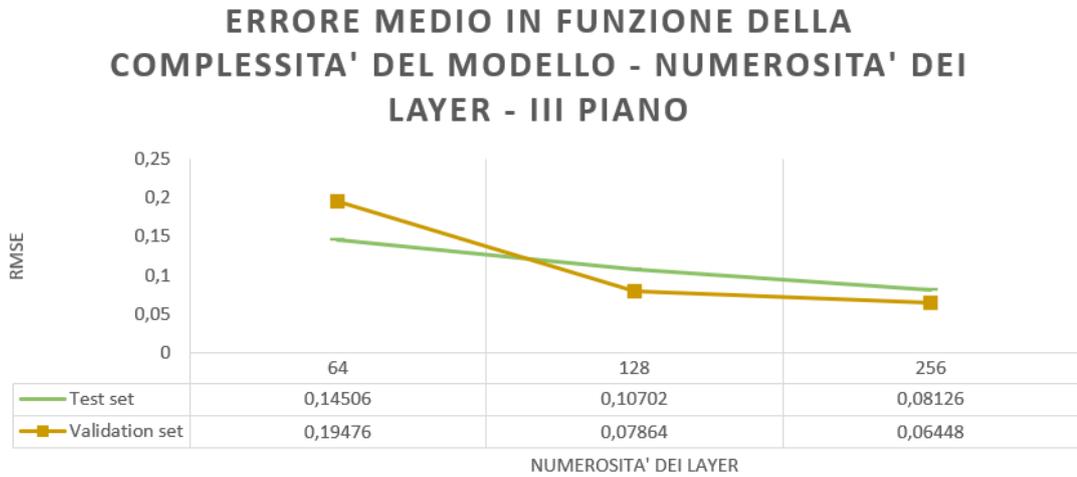


Figura 4.13: Errore medio in funzione della numerosità dei layer - III piano - Approccio MIMO

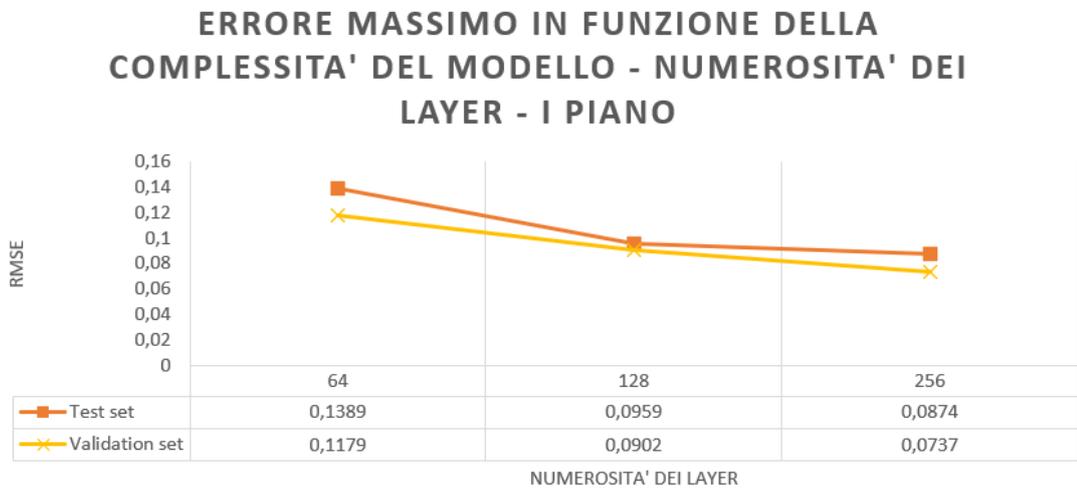


Figura 4.14: Errore massimo in funzione della numerosità dei layer - I piano - Approccio MIMO

ERRORE MASSIMO IN FUNZIONE DELLA COMPLESSITA' DEL MODELLO - NUMEROSITA' DEI LAYER - II PIANO

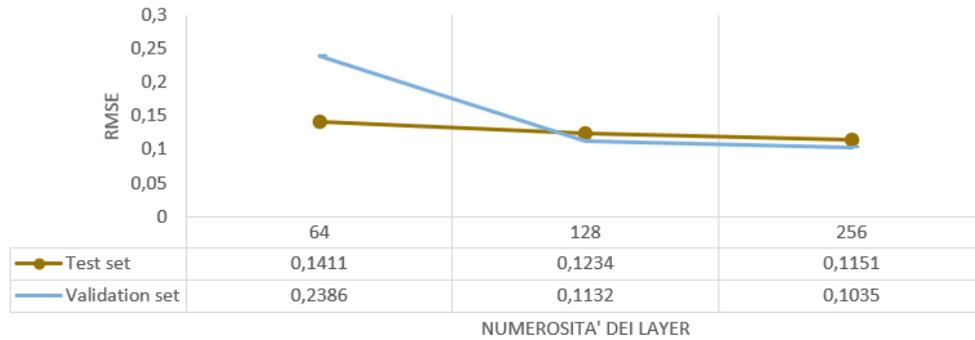


Figura 4.15: Errore massimo in funzione della numerosità dei layer - II piano - Approccio MIMO

ERRORE MASSIMO IN FUNZIONE DELLA COMPLESSITA' DEL MODELLO - NUMEROSITA' DEI LAYER - III PIANO

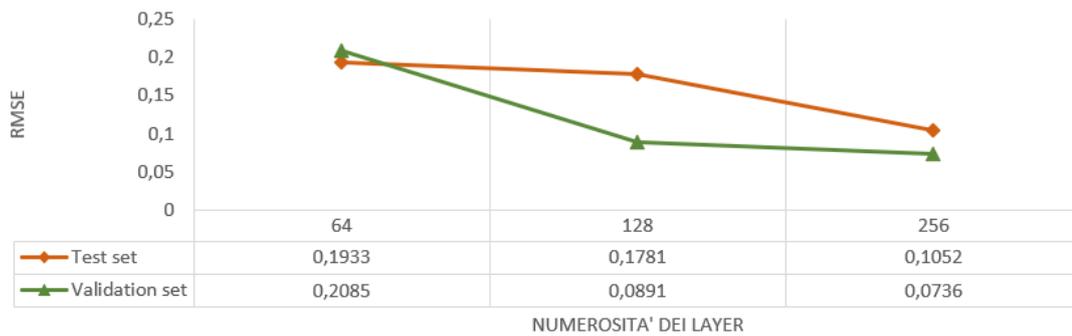


Figura 4.16: Errore massimo in funzione della numerosità dei layer - III piano - Approccio MIMO

Le migliori prestazioni ottenute con la numerosità di 256 neuroni per layer si realizzano però a spese di un progressivo aumento del tempo computazionale necessario per l'allenamento, che si spinge dai 15 secondi per epoca del caso più semplice fino ai 90 secondi per epoca nel caso della numerosità massima, richiedendo in totale 9000 secondi di allenamento, come si osserva in figura 4.17.

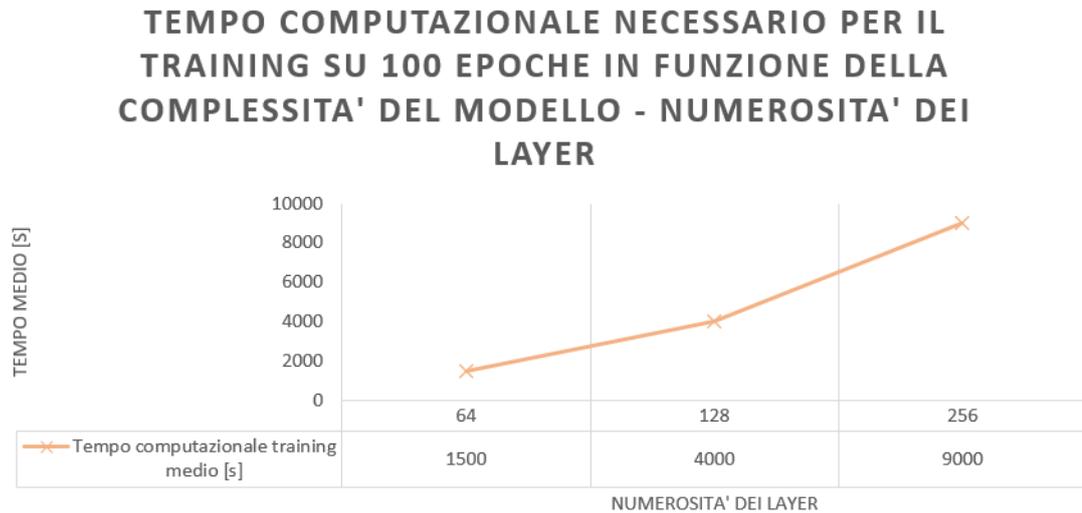


Figura 4.17: Tempo computazionale necessario per il training sui dati del I piano per 100 epoche e con un orizzonte di predizione di 5 ore in funzione della numerosità dei layer - Approccio MIMO

Influenza della presenza di dropout

Le prove proseguono tentando di identificare un eventuale vantaggio originato dalla presenza di una probabilità di dropout. La probabilità viene fatta variare dal 20% al 70%, passando per lo stadio intermedio del 50%, per osservare al meglio quale sia l'impatto del suo ammontare sull'accuratezza delle predizioni.

Come si può osservare nei relativi grafici (4.18 - 4.20), la probabilità di dropout causa un lieve ma costante innalzamento dell'errore registrato, sia per quanto riguarda il test set che il validation set. L'errore medio viene portato per tutti e tre i piani a sfiorare il limite di 0.1. Poiché non viene identificata l'evidenza di un miglioramento nelle performance con nessuna quota di probabilità di dropout, si esclude il suo utilizzo in questa sede.

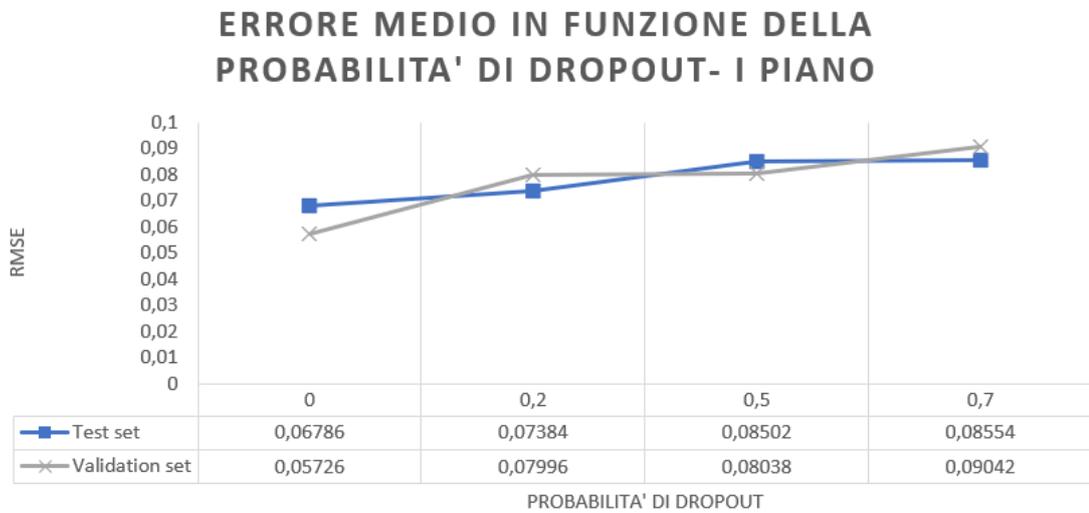


Figura 4.18: Errore medio in funzione della probabilità di dropout - I piano - Approccio MIMO

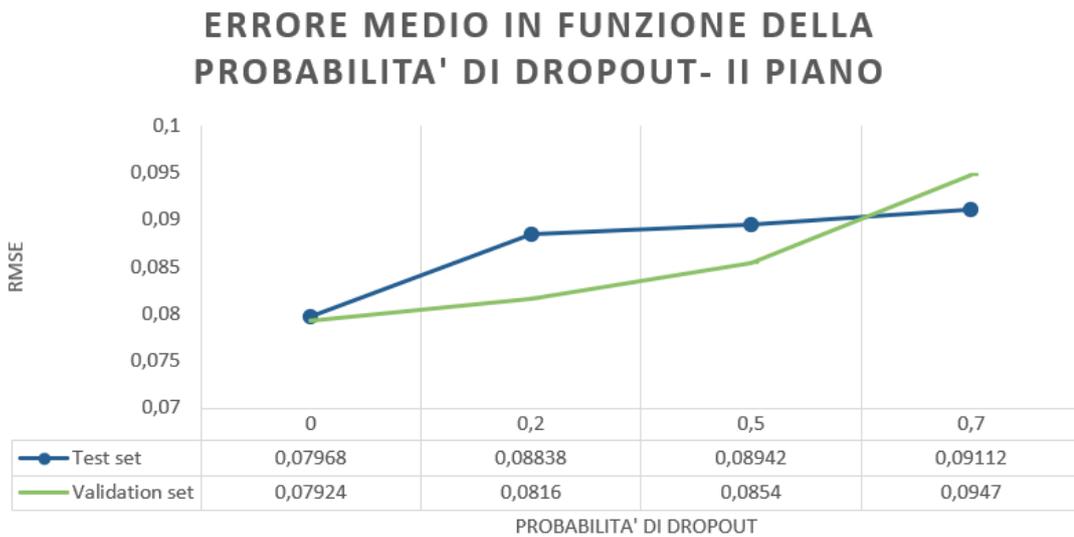


Figura 4.19: Errore medio in funzione della probabilità di dropout - II piano - Approccio MIMO

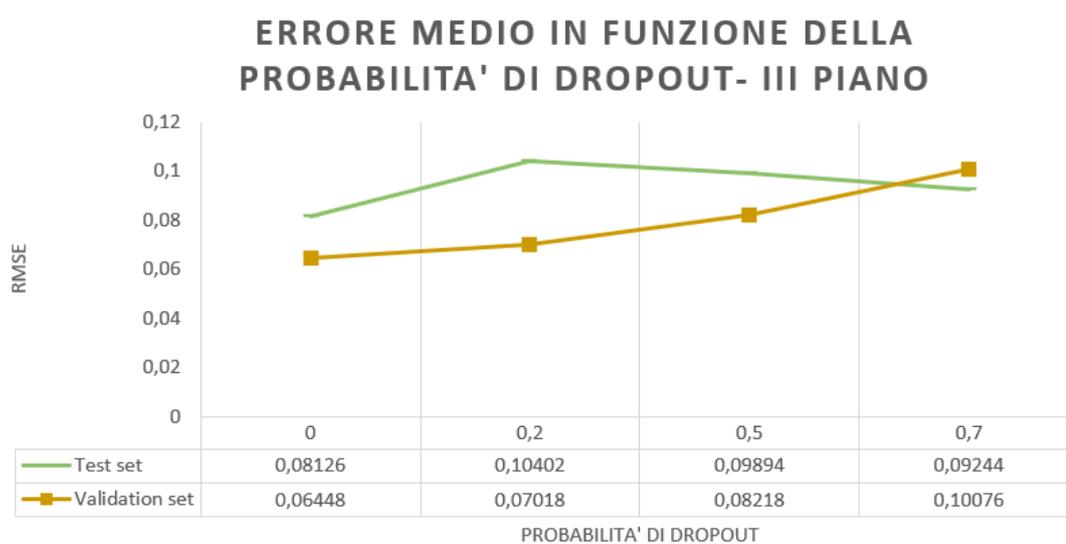


Figura 4.20: Errore medio in funzione della probabilità di dropout - III piano - Approccio MIMO

Influenza della struttura del modello

In questo paragrafo viene ponderata la possibilità di ricorrere a una struttura bidirezionale, nel caso sia essa migliorativa delle performance finora ottenute. Le prove vengono effettuate utilizzando i parametri determinati nelle sezioni precedenti, quindi con una numerosità di 256 neuroni e senza utilizzare alcuna probabilità di dropout.

I risultati mostrano che nel caso del primo piano, dove già erano stati ottenuti i migliori risultati, la struttura tradizionale conferma la propria superiorità. Al contrario, nelle altre due casistiche la struttura bidirezionale riesce a portare un lieve miglioramento complessivo, soprattutto per quanto riguarda il terzo piano (figure 4.21, 4.22). Il confronto tra le performance sui dati del secondo piano evidenzia una parità tra le due strutture, con un lievissimo vantaggio per quanto riguarda l'errore medio per la struttura bidirezionale, motivo per il quale essa è stata preferita per questo specifico orizzonte di tempo, ma non necessariamente anche per i successivi, come si dimostrerà più avanti. Un secondo aspetto da

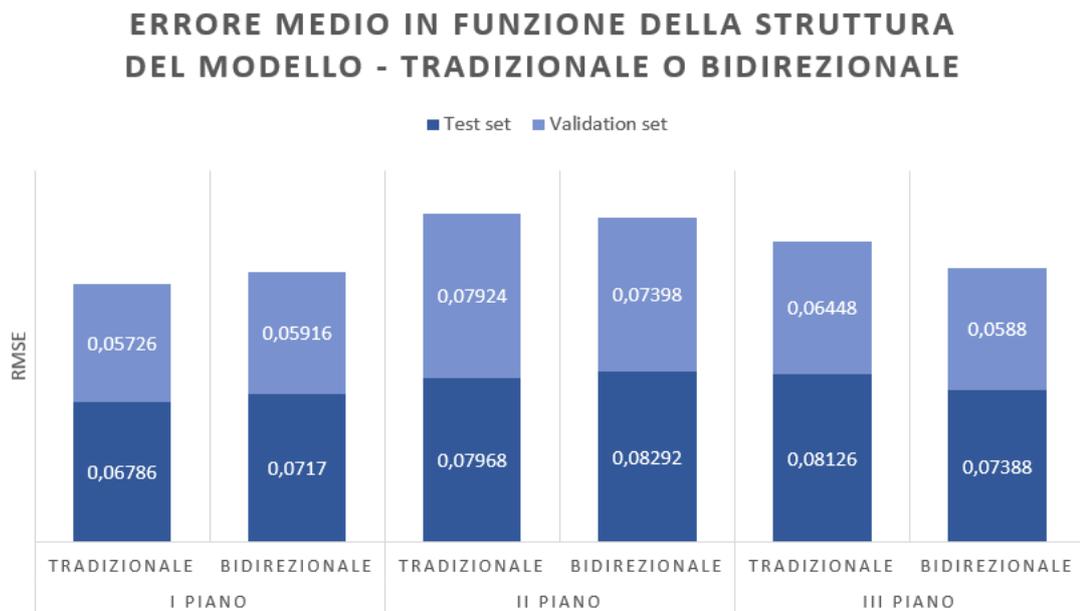


Figura 4.21: Errore medio per tutti e tre i piani in funzione della struttura del modello - Tradizionale o Bidirezionale - Approccio MIMO

sottolineare che potrebbe spingere a preferire una struttura bidirezionale è la significativa riduzione del tempo di allenamento: infatti, se con una numerosità di 256 la struttura tradizionale impiega 90 secondi circa per epoca per completare l'allenamento, alla rete bidirezionale sono necessari solo i due terzi di questo tempo,

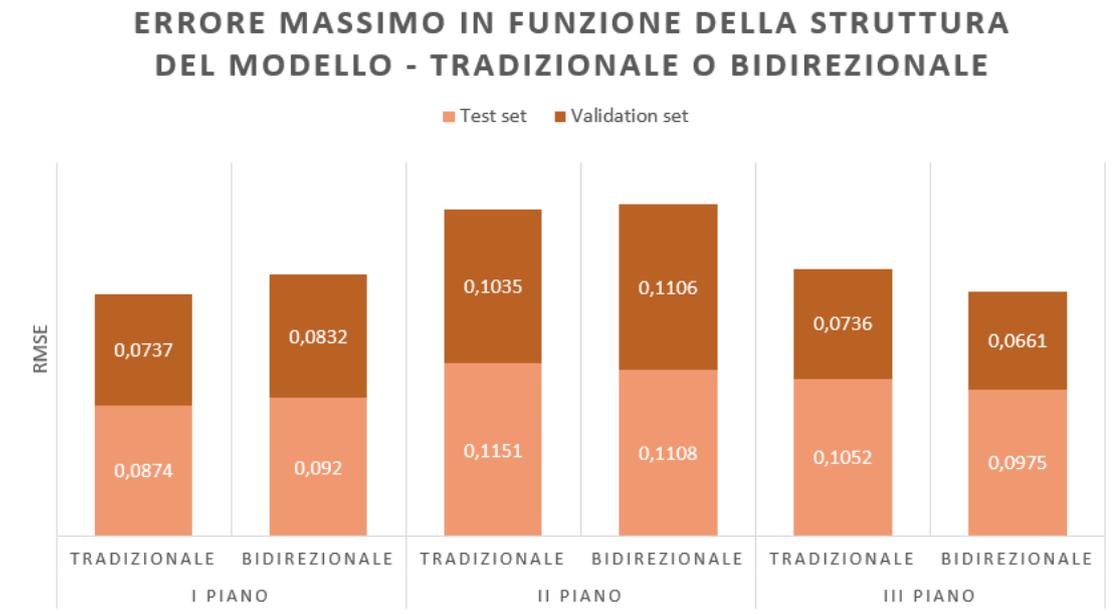


Figura 4.22: Errore massimo per tutti e tre i piani in funzione della struttura del modello - Tradizionale o Bidirezionale - Approccio MIMO

come si può osservare in figura 4.23. Conducendo un'analisi più approfondita a

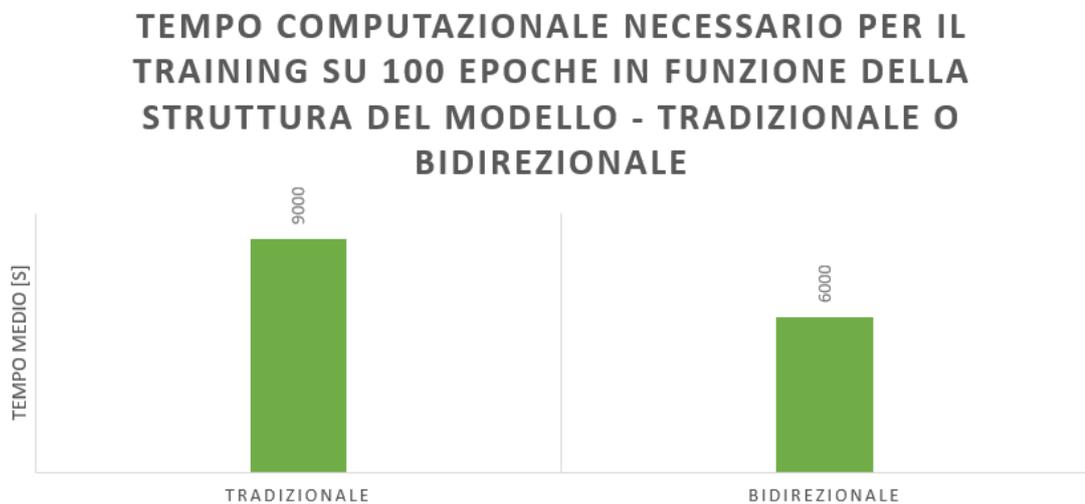


Figura 4.23: Tempo computazionale necessario per il training sui dati del I piano su 100 epoche in funzione della struttura del modello - Tradizionale o Bidirezionale - Approccio MIMO

riguardo, però, è possibile notare che le prestazioni della rete di natura bidirezionale sono molto più affette dall'ampiezza dell'orizzonte di tempo rispetto a quelle della rete tradizionale. Se, in ogni caso, l'allargamento dell'orizzonte di tempo causa un aumento dell'errore, tale aumento si presenta molto più pronunciato nel caso della rete bidirezionale, sia osservando l'errore medio (figure 4.24) che un errore massimo (figura 4.25), frutto della media fra gli errori massimi. I grafici, infatti, dimostrano che la struttura bidirezionale nel complesso si rivela la scelta migliore per gli orizzonti di tempo più ristretti (2 ore e 5 ore), dove infatti essa è stata prescelta nei due terzi dei casi, per i piani secondo e terzo. La tendenza si inverte però per l'intervallo di tempo più lungo (24 ore), dove la struttura tradizionale risulta la più appropriata per tutti e tre i casi a causa di un significativo e congiunto aumento dell'errore che non si riscontra con eguale rilevanza nella struttura tradizionale.

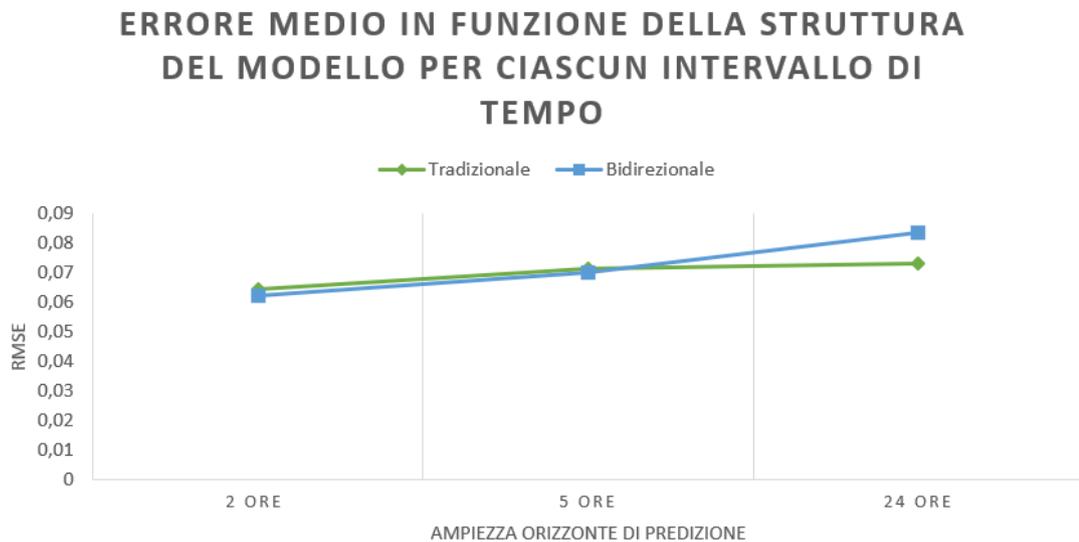


Figura 4.24: Errore medio su tutti e tre i piani in funzione della struttura del modello - Tradizionale o Bidirezionale - per ciascun orizzonte di tempo - Approccio MIMO

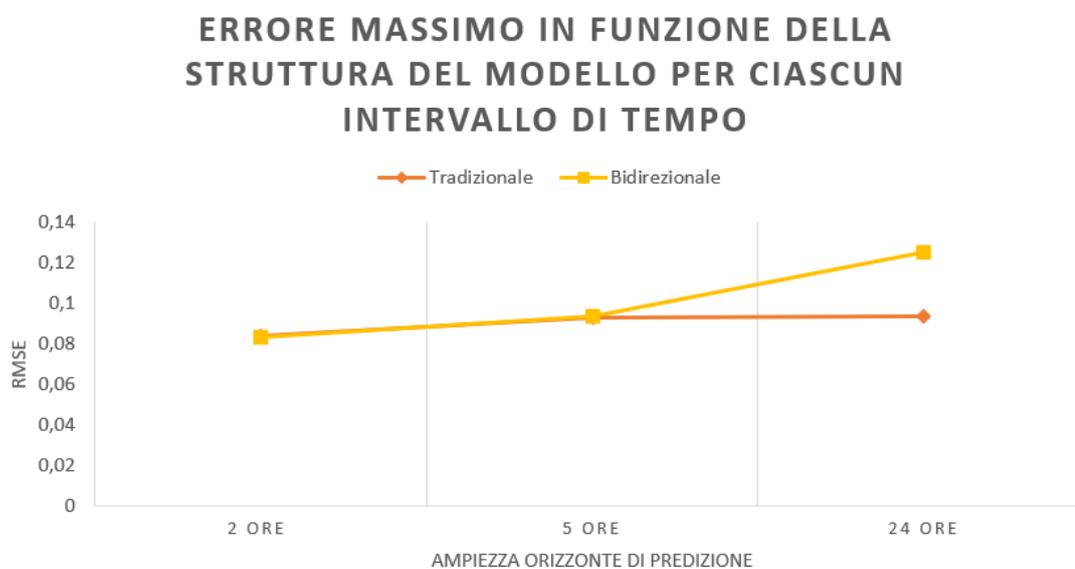


Figura 4.25: Media su tutti e tre i piani dell'errore massimo in funzione della struttura del modello - Tradizionale o Bidirezionale - per ciascun orizzonte di tempo - Approccio MIMO

Influenza della funzione di loss

La funzione di loss è un parametro significativo che potrebbe impattare in modo notevole sulle performance del modello, motivo per il quale nel prossimo paragrafo vengono osservate le variazioni dell'errore misurato nel caso in cui sia adottata una funzione di perdita calcolata con la metrica Mean Absolute Error (MAE) oppure nel caso in cui sia adottata una funzione di perdita calcolata con la metrica Mean Squared Error (MSE). Le prove sono condotte tenendo conto che è assodato che per l'orizzonte di tempo in uso la struttura tradizionale è preferibile soltanto per i dati relativi al primo piano.

Come si evince dalle figure 4.26 e 4.27, la funzione di perdita ottimale varia in funzione della zona di riferimento. La metrica MAE, per quanto riguarda l'ampiezza dell'orizzonte di tempo presa in considerazione, si rivela più performante per il terzo piano; al contrario, la metrica MSE risulta nettamente superiore per il primo piano. Infine, per il secondo piano anche in questo caso non esiste una distinzione particolarmente netta, ma poiché la metrica MSE garantisce un errore massimo più contenuto, essa è stata ritenuta la più adeguata.

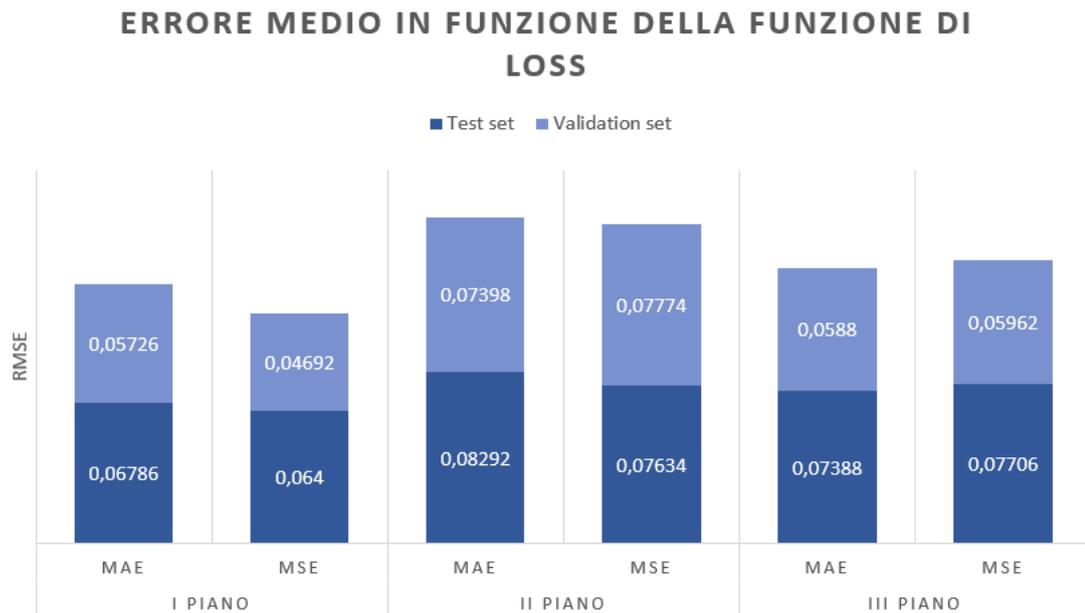


Figura 4.26: Errore medio in funzione della funzione di loss per un intervallo di predizione di 5 ore e tutti e tre i piani - Approccio MIMO

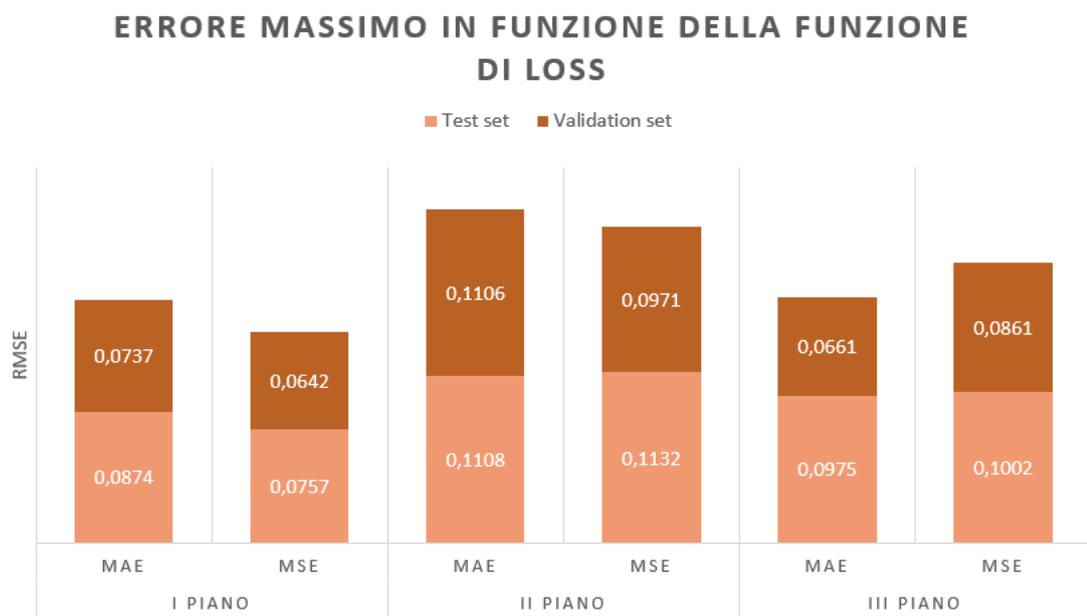


Figura 4.27: Errore massimo in funzione della funzione di loss per un intervallo di predizione di 5 ore e tutti e tre i piani - Approccio MIMO

Influenza dell'optimizer scelto

In questo paragrafo viene motivata la scelta riguardante l'ottimizzatore fra i tre proposti inizialmente. Si è ritenuto necessario individuare gli ottimizzatori più opportuni in funzione di ciascun intervallo di predizione considerato. Adam risulta l'ottimizzatore in grado di restituire le migliori performance. Si nota dai grafici di

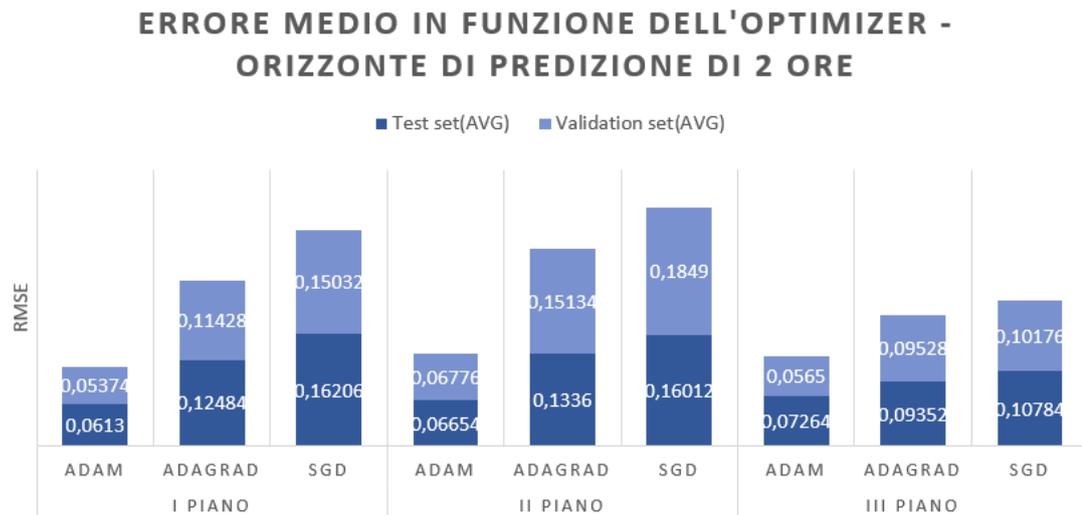


Figura 4.28: Errore medio in funzione di ciascun ottimizzatore per un intervallo di predizione di 2 ore e tutti e tre i piani - Approccio MIMO

riferimento (4.28-4.30), però, come il trend per gli ottimizzatori SGD e Adagrad, contrariamente ad Adam, non sia quello di non accrescere il proprio errore con l'aumentare dell'ampiezza dell'orizzonte di predizione, evidenziato in particolare in figura 4.31. Dunque, con orizzonti di predizione più estesi, la preferenza di Adam, che invece tende in questo caso ad aumentare i propri errori ampliando l'orizzonte, non è assolutamente scontata, in particolare nel caso del dataset riguardante il terzo piano, dove le performance di Adagrad e SGD risultano sempre piuttosto in linea con quelle di Adam, contrariamente agli altri due casi dove spesso l'errore complessivo a essi legato può essere perfino doppio o triplo.

Influenza dell'ampiezza dell'orizzonte di predizione

Come già accennato, è evidente che la scelta di un orizzonte di predizione più o meno esteso impatta in modo significativo sui risultati ottenuti: per questo motivo, si è ritenuto opportuno selezionare per ciascun orizzonte di tempo ed ogni piano una combinazione di parametri che garantisca un set di predizioni il più vicine possibile alla realtà. Le prove, dunque, hanno comportato l'utilizzo di entrambe le funzioni

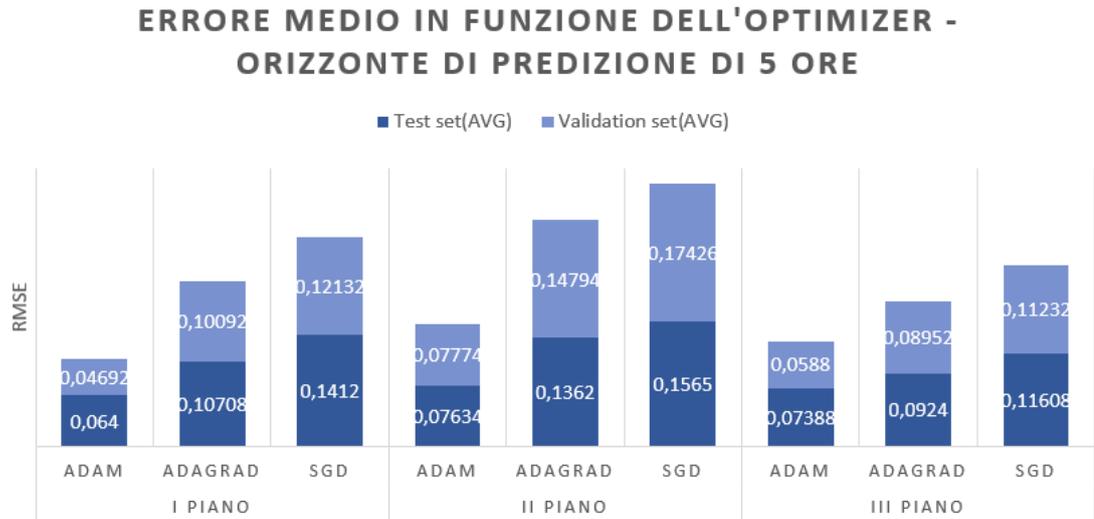


Figura 4.29: Errore medio in funzione di ciascun ottimizzatore per un intervallo di predizione di 5 ore e tutti e tre i piani - Approccio MIMO

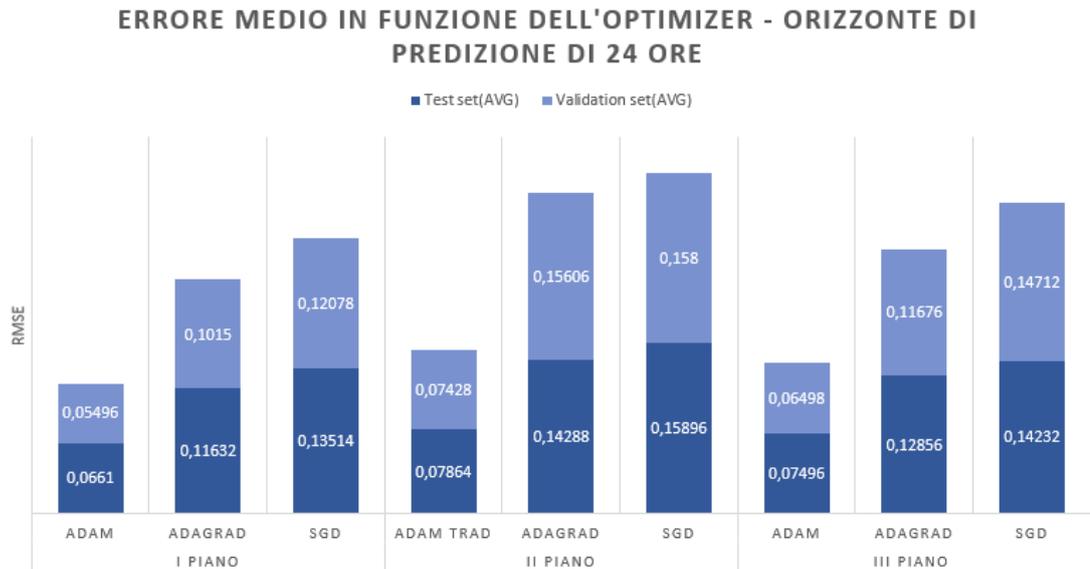


Figura 4.30: Errore medio in funzione di ciascun ottimizzatore per un intervallo di predizione di 24 ore e tutti e tre i piani - Approccio MIMO

di perdita, di diverse strutture del modello e di tutti e tre gli ottimizzatori. Se da un lato Adam è stato l'ottimizzatore universalmente scelto per tutte le casistiche, non si può dire lo stesso della funzione di loss come della struttura, per la quale,

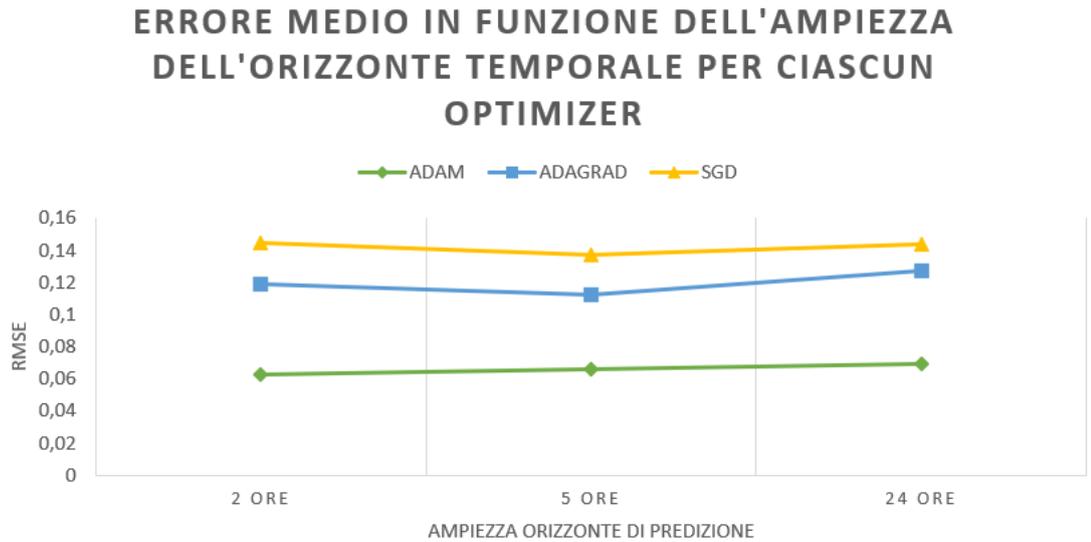


Figura 4.31: Errore medio sui tre piani per ciascun ottimizzatore in funzione dell'intervallo di predizione - Approccio MIMO

come anticipato, è richiesto un ritorno alla struttura tradizionale per i piani II e III con l'orizzonte di tempo di 24 ore.

Nei grafici sottostanti (4.31-4.34), vengono riportati i risultati selezionati per ogni orizzonte di tempo. Anche, dunque, risalendo all'errore minimo ottenibile, si osserva che l'allungamento dell'orizzonte di tempo porta un lieve aumento dell'errore complessivo, che comunque rimane in ciascun caso contenuto e molto al di sotto della soglia di 0.1 per quanto riguarda la metrica RMSE. Lo stesso trend crescente si evidenzia effettuando il calcolo con la metrica MAE, dove gli errori allo stesso modo rimangono del tutto accettabili e non superano mai il limite di 0.07. Il grafico 4.31 mette in evidenza il trend registrato, mentre i grafici 4.32 e 4.33 sono in grado di sintetizzare i risultati ottenuti come media fra test set e validation set per ogni piano. In aggiunta, nei grafici 4.35, 4.36 e 4.37 è possibile osservare anche la distribuzione dell'errore, suddivisa per ogni piano e per ogni orizzonte di predizione.

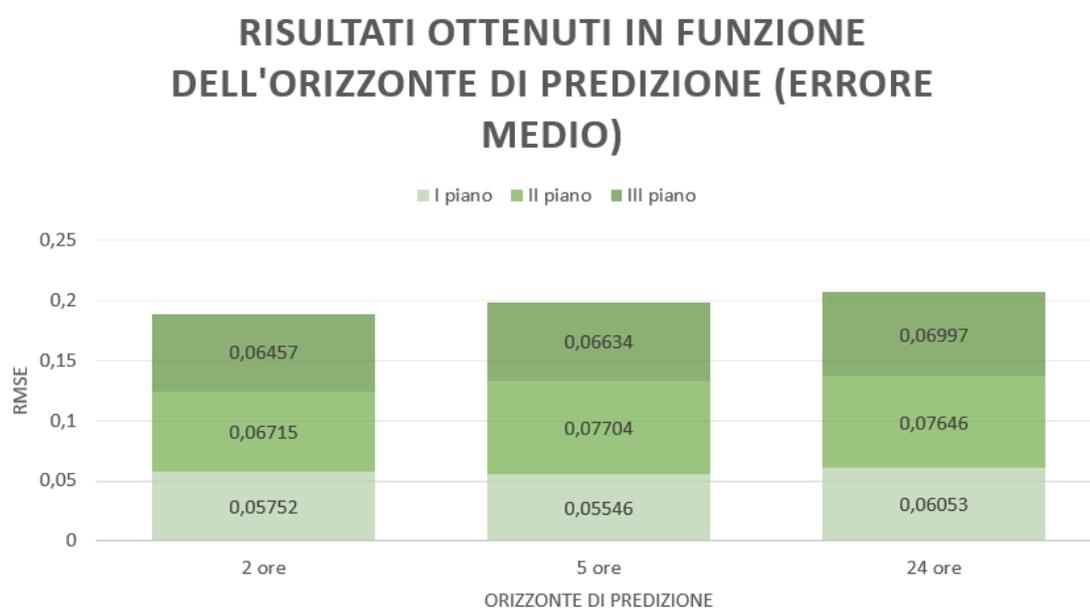


Figura 4.32: Errore medio (RMSE) di tutti e tre i piani ottenuto con l'ottimizzatore e la funzione di loss selezionata per ciascun orizzonte di predizione - Approccio MIMO

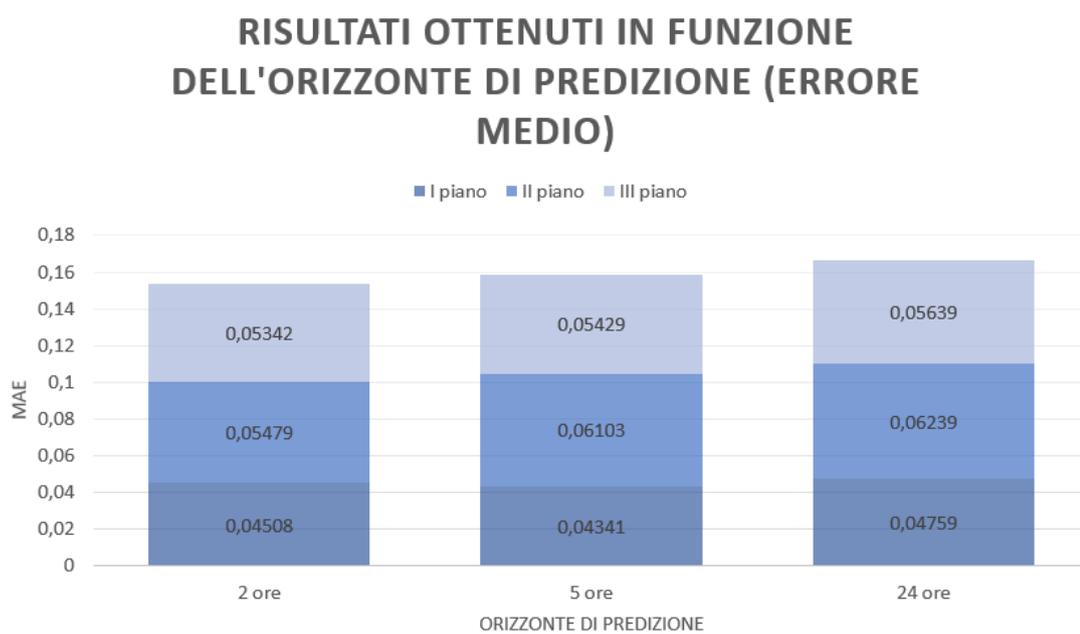


Figura 4.33: Errore medio (MAE) di tutti e tre i piani ottenuto con l'ottimizzatore e la funzione di loss determinata per ciascun orizzonte di predizione - Approccio MIMO

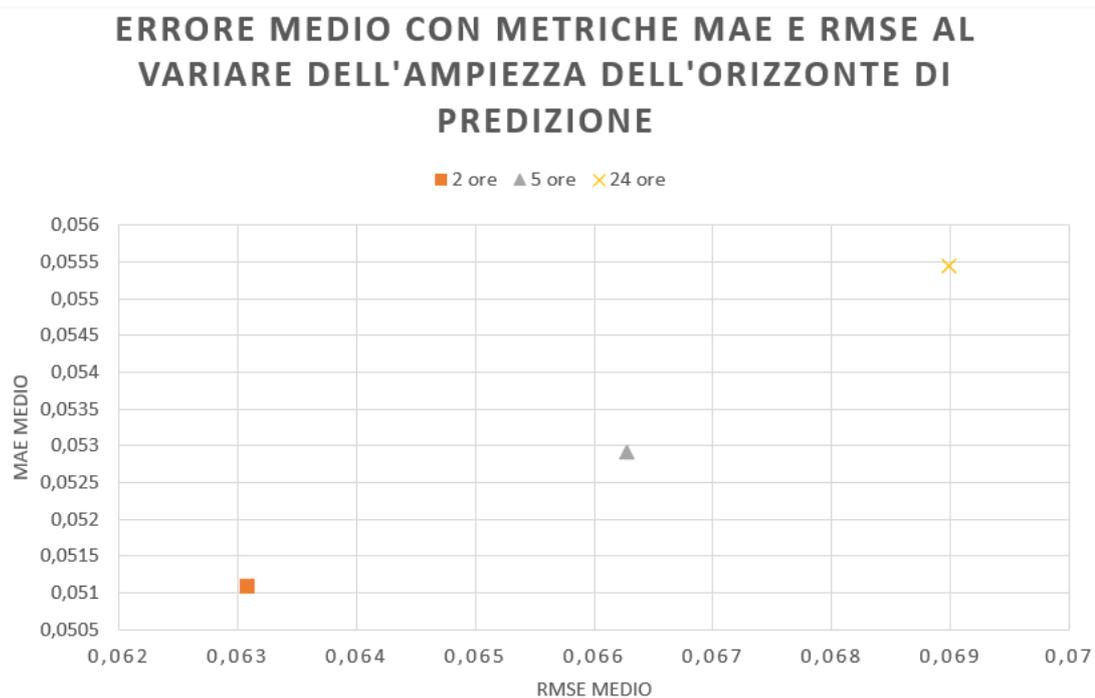


Figura 4.34: Errore medio (RMSE e MAE) calcolati su tutti e tre i piani con l'ottimizzatore e la funzione di loss determinata per ciascun orizzonte di predizione - Approccio MIMO

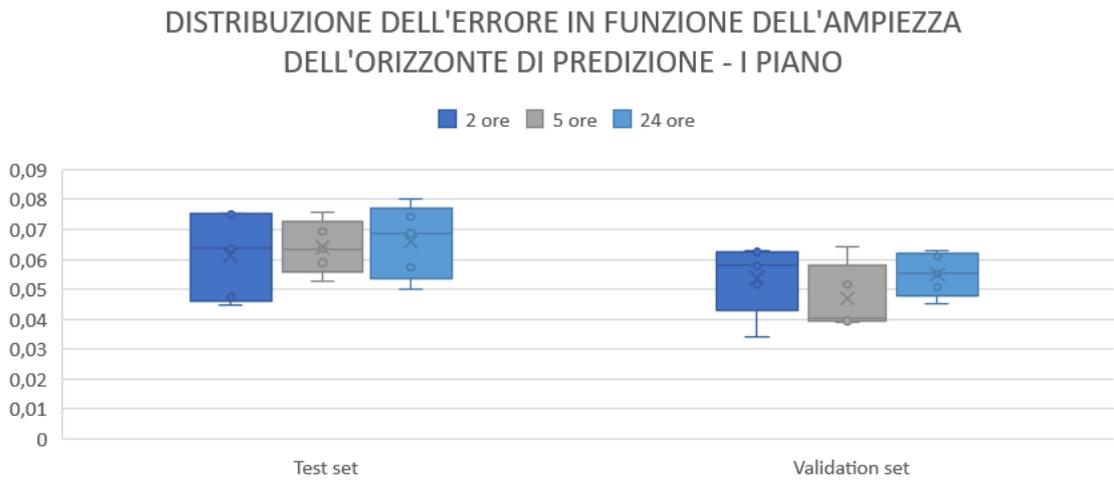


Figura 4.35: Distribuzione dell'errore medio RMSE ottenuto con funzione di loss e ottimizzatore selezionati in funzione dell'orizzonte di predizione - I piano - Approccio MIMO

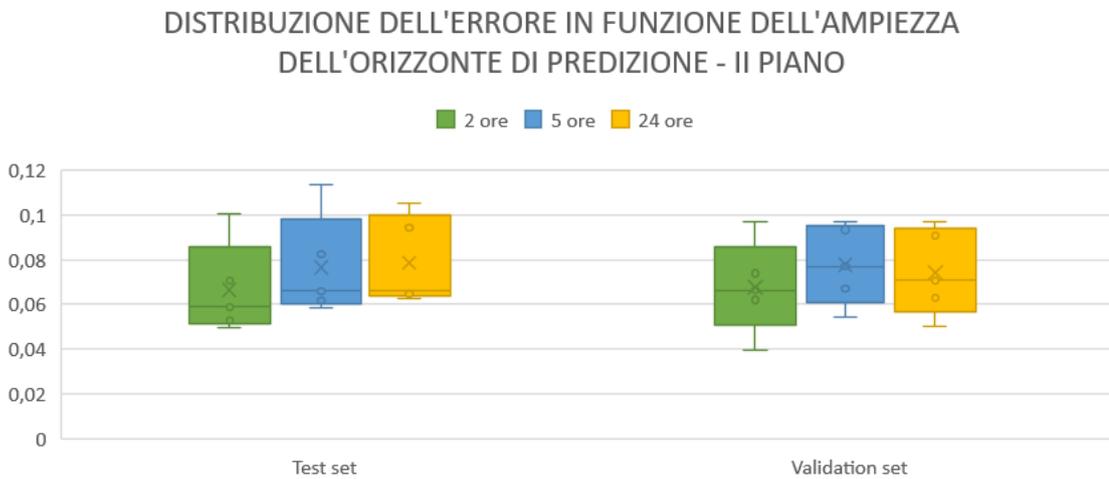


Figura 4.36: Distribuzione dell'errore medio RMSE ottenuto con funzione di loss e ottimizzatore selezionati in funzione dell'orizzonte di predizione - II piano - Approccio MIMO

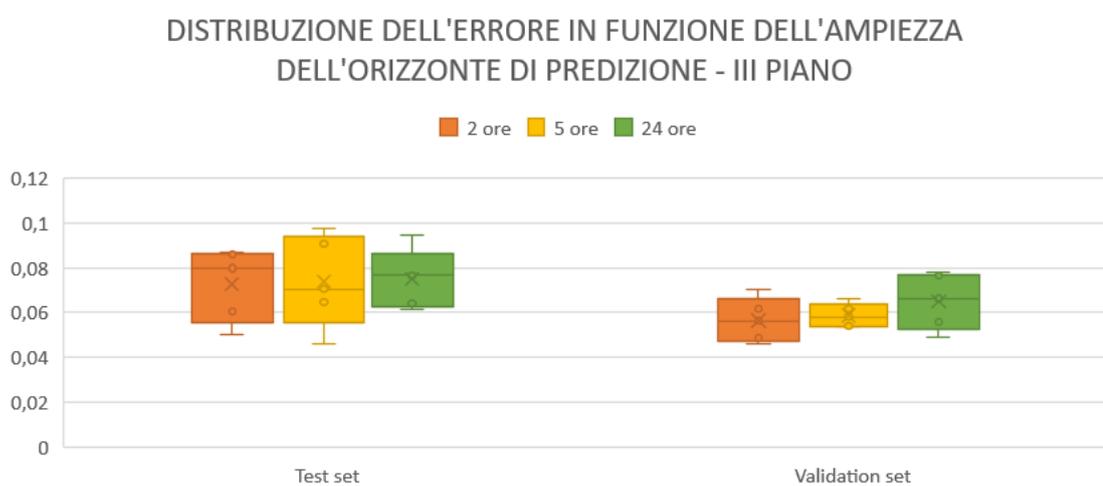


Figura 4.37: Distribuzione dell'errore medio RMSE ottenuto con funzione di loss e ottimizzatore selezionati in funzione dell'orizzonte di predizione - III piano - Approccio MIMO

Influenza del piano di riferimento

I risultati presentati hanno già mostrato una differenza nella prestazioni in funzione del piano target. Essa è riconducibile alla diversa complessità delle tre situazioni perché, a causa della loro posizione, i tre piani sono caratterizzati da dinamiche diverse relativamente alla trasmissione del calore, la risposta termica e quindi l'apporto delle variabili in input nella determinazione del parametro target. Il primo piano subisce l'influenza del piano sovrastante, mentre per la parte inferiore si trova a contatto con il piano seminterrato, caratterizzato dunque da tutt'altro genere di climatizzazione. Il secondo piano, per via della sua posizione centrale, subisce la doppia influenza del primo e del terzo piano, rendendo di fatto la determinazione della variabile target più complessa a causa degli effetti secondari. Il terzo piano, infine, non solo si trova a contatto con il secondo piano, ma presenta anche l'incognita della copertura del tetto, che presenta delle proprietà termiche differenti e inconciliabili con quelle degli involucri che caratterizzano gli altri piani. Ne consegue che l'ipotesi di non influenza fra le zone conduce a trascurare alcune dinamiche e a creare un inevitabile disallineamento delle predizioni dai valori effettivi.

Sommariamente, osservando il relativo grafico 4.38, si osserva che la posizione del secondo piano è quella che maggiormente penalizza la capacità di predizione: è qui che l'errore RMSE medio fra i risultati ottenuti con i vari orizzonti di tempo, infatti, supera sia nel test che nella validazione la soglia di 0.07. I migliori risultati si ottengono con il primo piano, dove si arriva a sfiorare il minimo di 0.05 per la metrica RMSE. Il terzo piano si colloca in una posizione intermedia, con una media di RMSE di 0.067 circa. Un'ulteriore analisi conferma che è proprio sul secondo e terzo piano che l'influenza dell'allungamento dell'orizzonte di predizione si fa maggiormente sentire: infatti, osservando il grafico 4.39, si nota che è proprio sul secondo e in particolare sul terzo piano che l'errore complessivo per gli orizzonti di tempo più estesi si distacca più nettamente rispetto a quello relativo all'orizzonte di tempo più ridotto

ERRORE MEDIO IN FUNZIONE DEL PIANO DI RIFERIMENTO

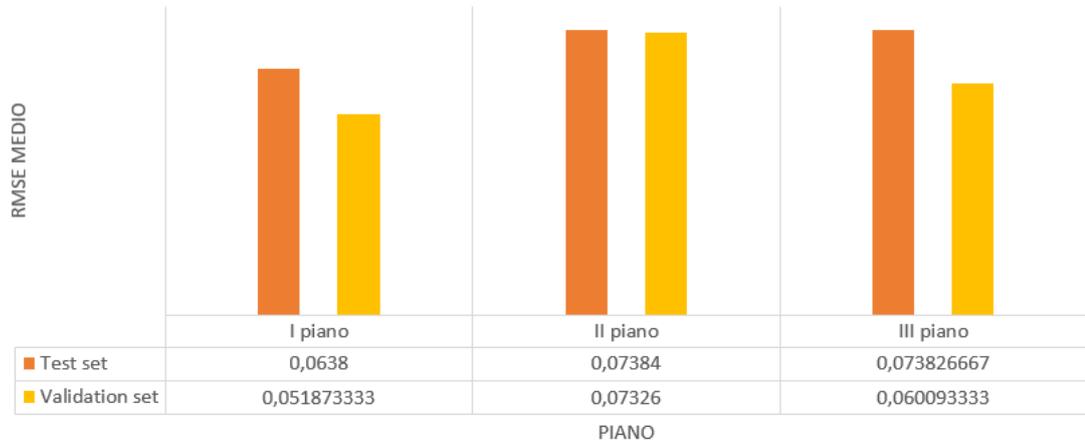


Figura 4.38: Errore medio sui tre orizzonti di predizione con l'ottimizzatore e la funzione di loss selezionate in funzione del piano di riferimento - Approccio MIMO

ERRORE MEDIO IN FUNZIONE DELL'ORIZZONTE DI TEMPO

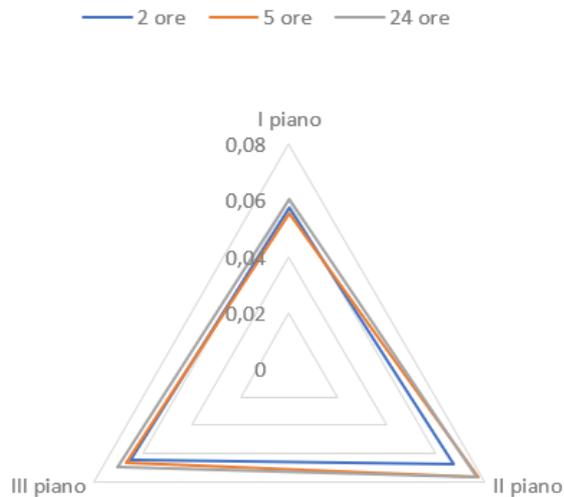


Figura 4.39: Errore medio in funzione dei tre orizzonti di predizione con l'ottimizzatore e la funzione di loss selezionate e in funzione del piano di riferimento - Approccio MIMO

Influenza della posizione relativa dell'ufficio

Si conclude con un'ultima indagine, il cui scopo è comprendere se la posizione relativa di un ufficio rispetto al piano di riferimento possa influire sistematicamente sulle precisioni delle predizioni del modello. I risultati (figura 4.40) mostrano che non esistono particolari criticità per alcuni uffici in particolare, anche se i massimi discostamenti si verificano sistematicamente per l'ufficio numero 39, che è l'unico caso dove i massimi talvolta superano la soglia di 0.1 di RMSE. A parte questa sottile differenza, il resto delle prestazioni si dimostra equilibrato, confermando una generale uniformità dello scostamento dei valori predetti rispetto ai valori effettivi.

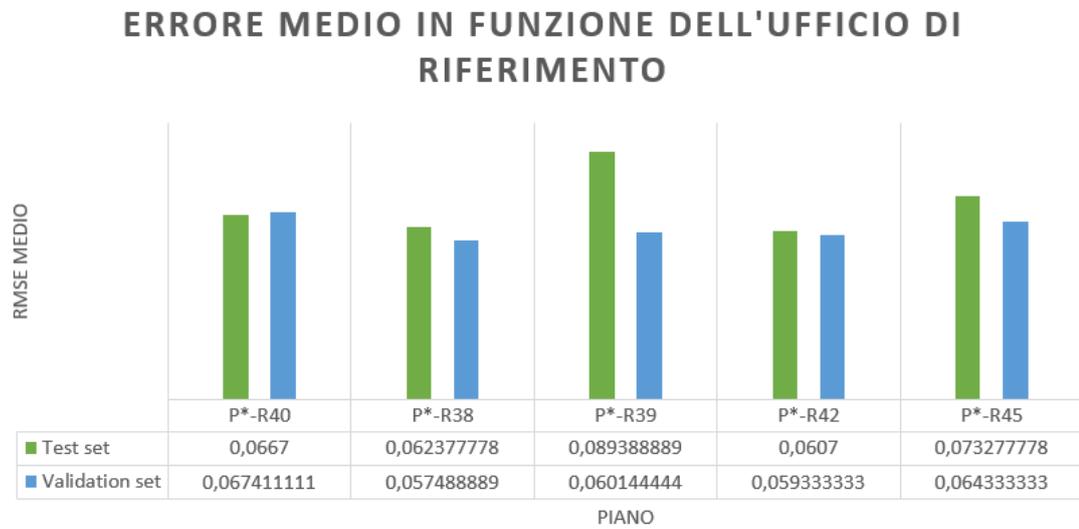


Figura 4.40: Errore medio sui tre orizzonti di predizione e sui tre piani con l'ottimizzatore e la funzione di loss selezionate in funzione dell'ufficio di riferimento - Approccio MIMO

Influenza dell'approccio

Se l'approccio Multi Output è quello, fra i due considerati, in grado di fornire un risultato più completo, tuttavia deve confrontarsi con una maggiore complessità, da cui viene sistematicamente penalizzato. Si nota, infatti, che la predizione della stessa variabile, la temperatura ambiente nell'ufficio R-40, con un approccio Multi Output è sistematicamente più imprecisa, poiché è stato necessario per il modello identificare anche le dinamiche che influenzano le altre variabili predette. Si tratta di un trend molto evidente: con nessun orizzonte di tempo, per nessun piano, l'errore caratteristico dell'approccio Multi Output, ottenuto con una media fra quello registrato sul test set e sul validation set, riesce a rimanere contenuto quanto quello ottenuto con un approccio Single Output.

ERRORE MEDIO IN FUNZIONE DELL'APPROCCIO

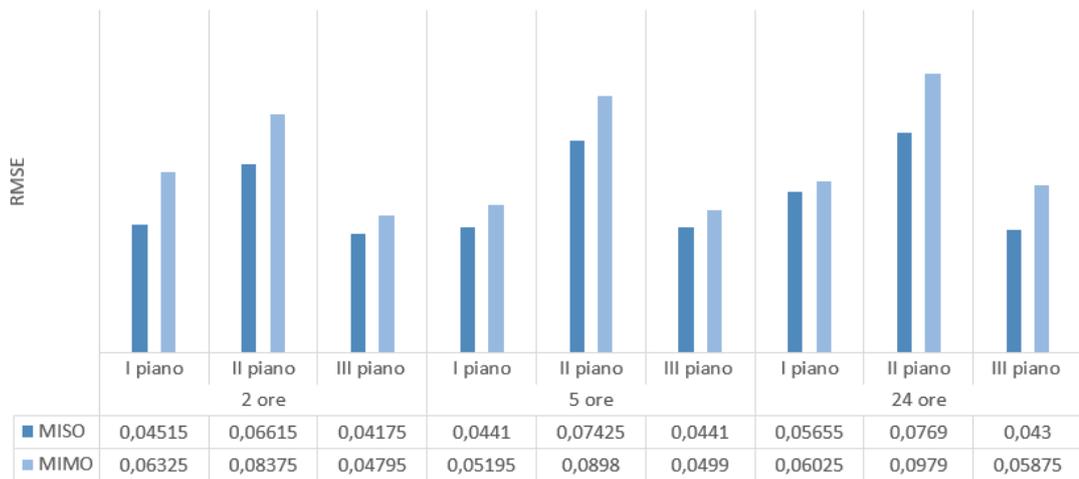


Figura 4.41: Errore medio per ciascun piano e per ciascun intervallo di predizione in funzione dell'approccio

Di seguito (figure 4.41 - 4.101) vengono riportati i profili dei valori predetti per ciascun ufficio con un orizzonte di tempo di predizione di 2 ore, sia per il test set che per il validation set. Inoltre, tramite i grafici si può osservare l'aderenza dei valori predetti a quelli effettivi. Per brevità, le rappresentazioni riguardano soltanto l'orizzonte di predizione più breve (2 ore).

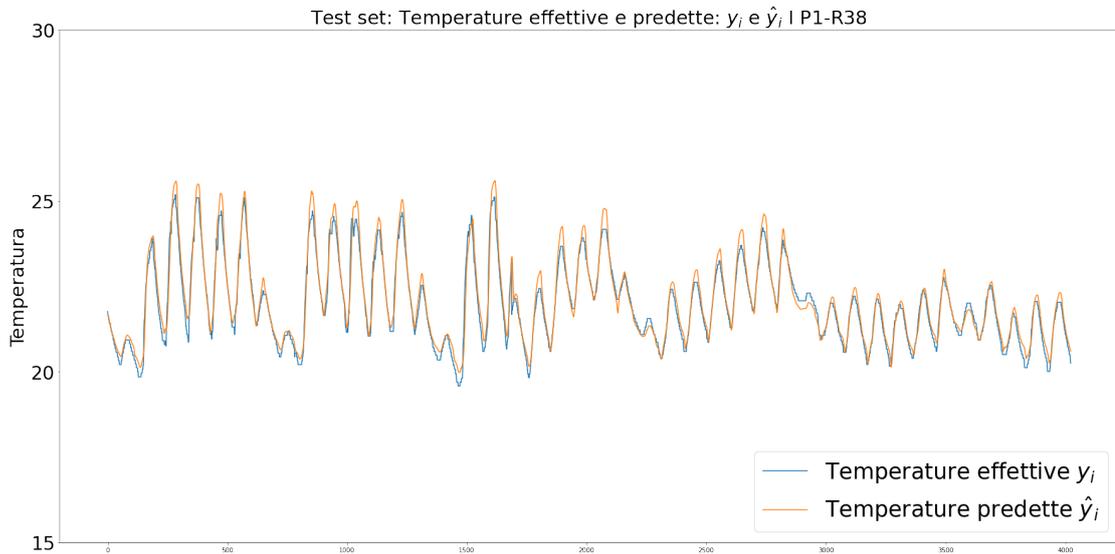


Figura 4.42: Temperature effettive e predette - orizzonte di predizione di 2 ore - test set P1R38 - Approccio MIMO

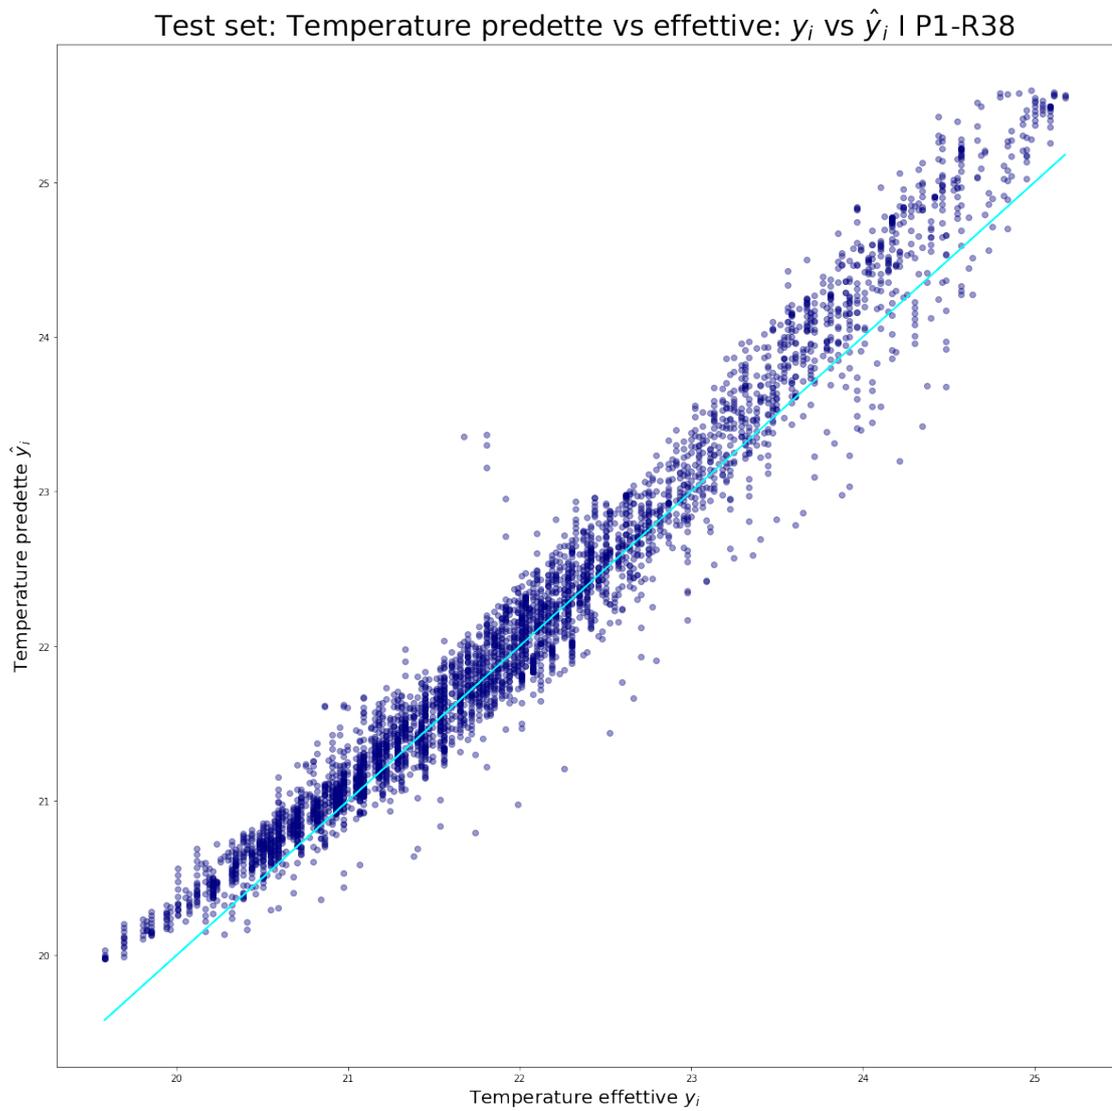


Figura 4.43: Temperature effettive vs predette - orizzonte di predizione di 2 ore - test set P1R38 - Approccio MIMO

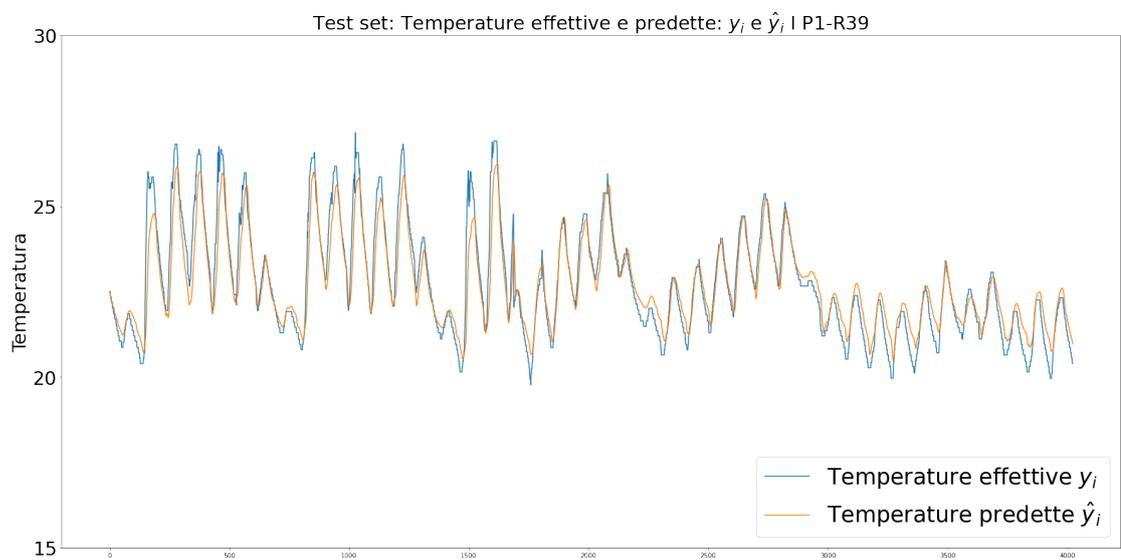


Figura 4.44: Temperature effettive e predette - orizzonte di predizione di 2 ore - test set P1R39 - Approccio MIMO

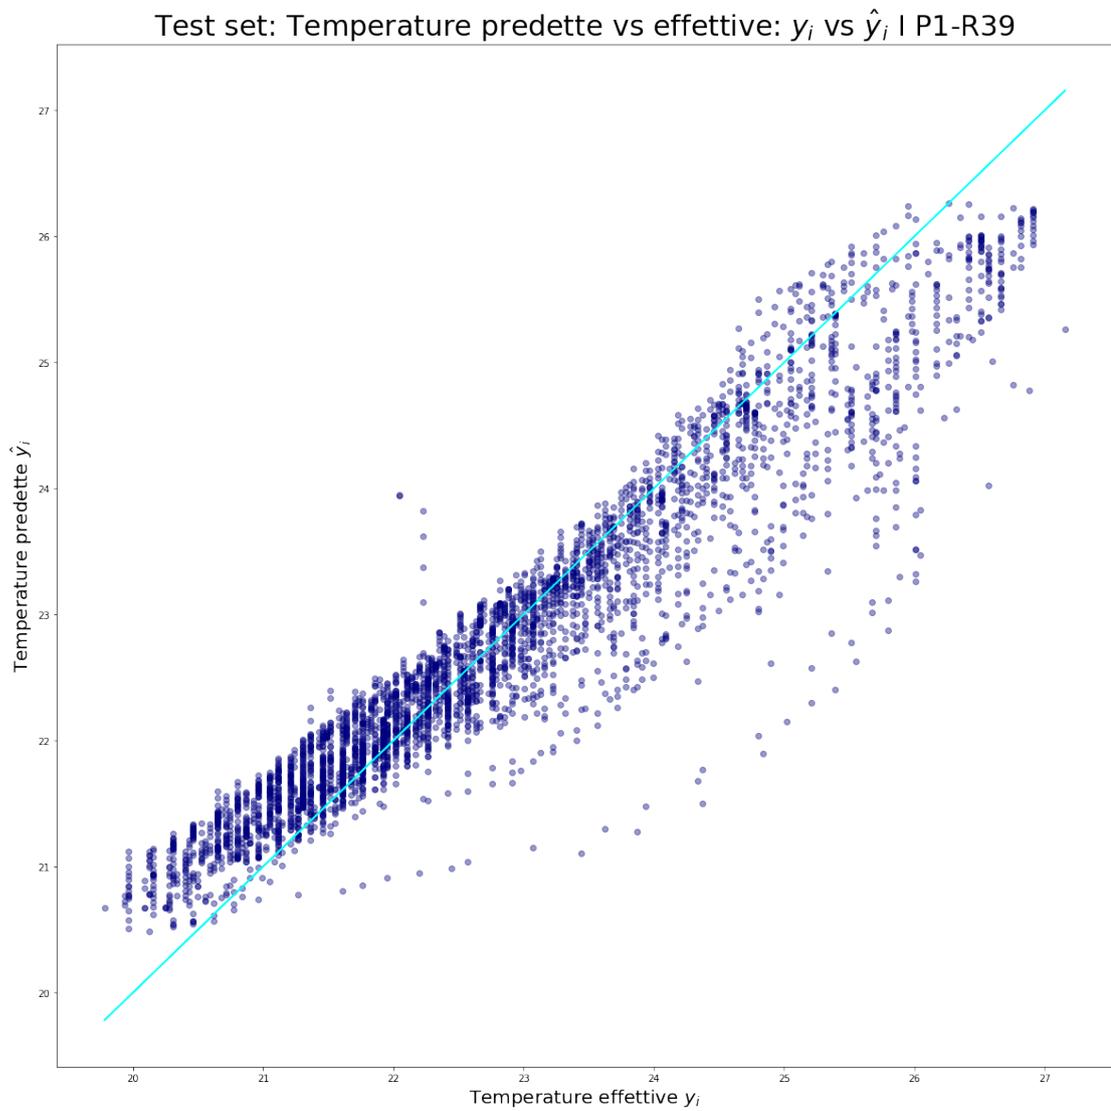


Figura 4.45: Temperature effettive vs predette - orizzonte di predizione di 2 ore - test set P1R39 - Approccio MIMO

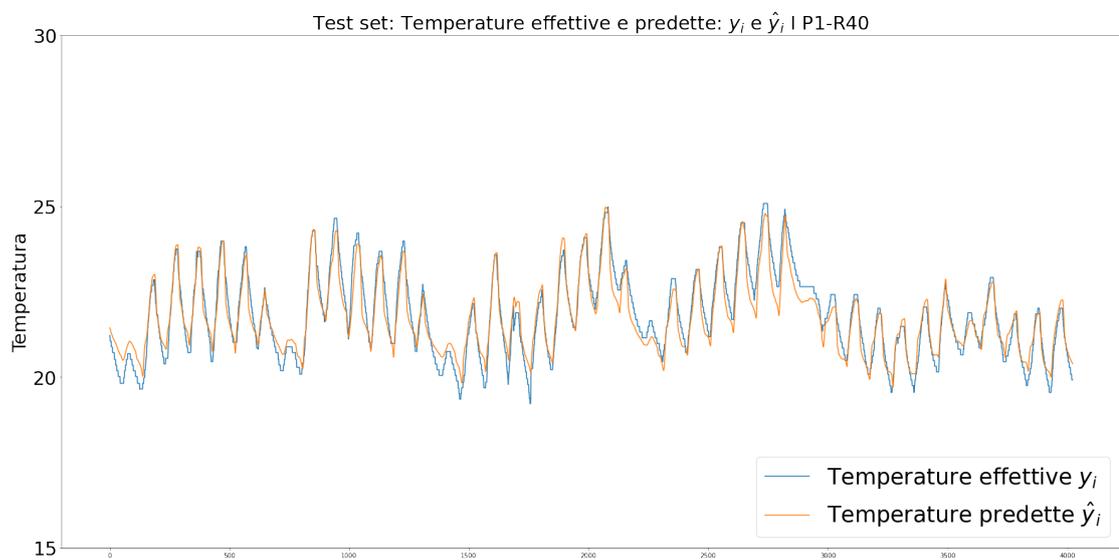


Figura 4.46: Temperature effettive e predette - orizzonte di predizione di 2 ore - test set P1R40 - Approccio MIMO

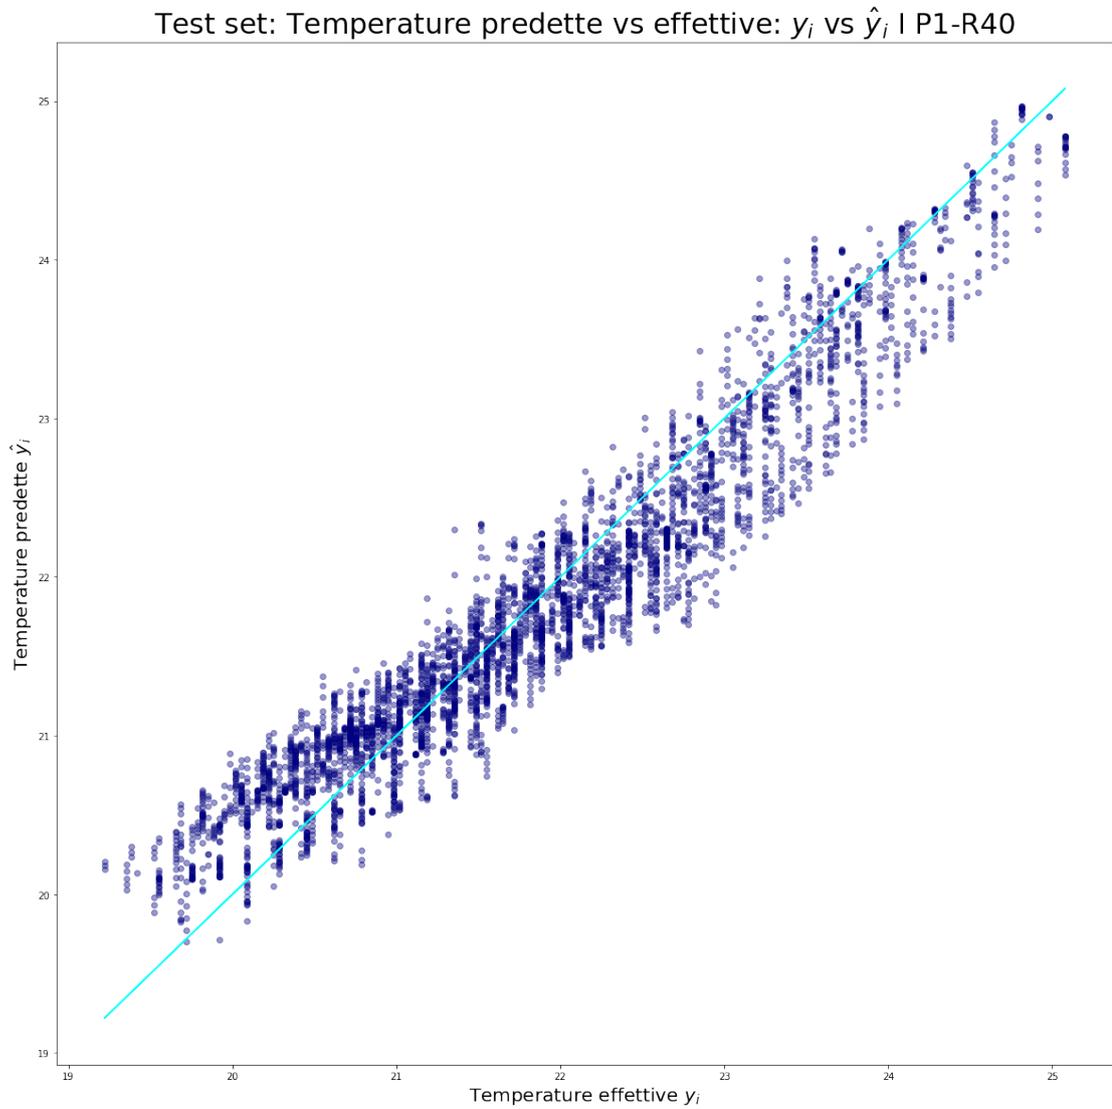


Figura 4.47: Temperature effettive vs predette - orizzonte di predizione di 2 ore - test set P1R40 - Approccio MIMO

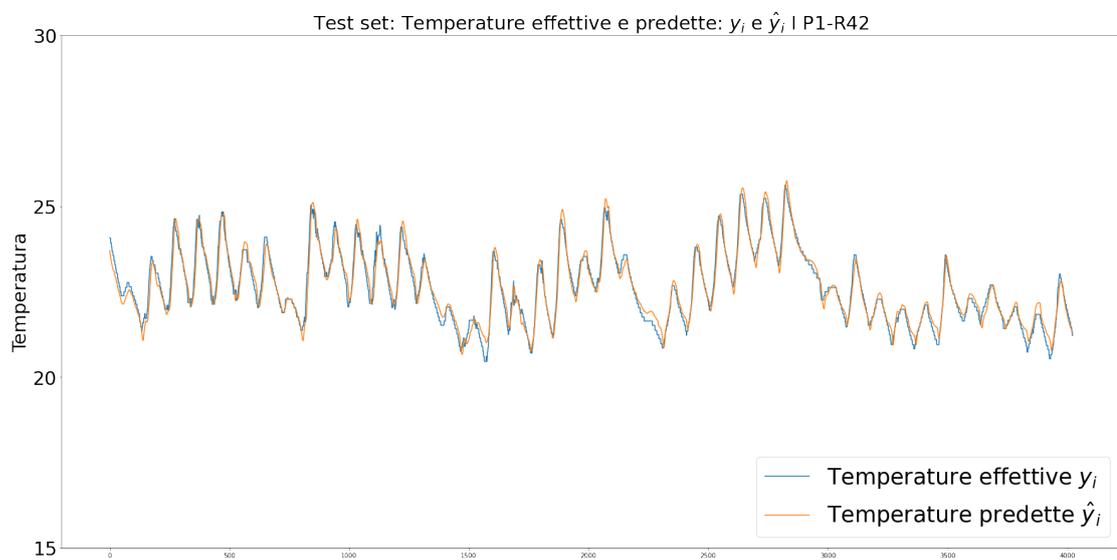


Figura 4.48: Temperature effettive e predette - orizzonte di predizione di 2 ore - test set P1R42 - Approccio MIMO

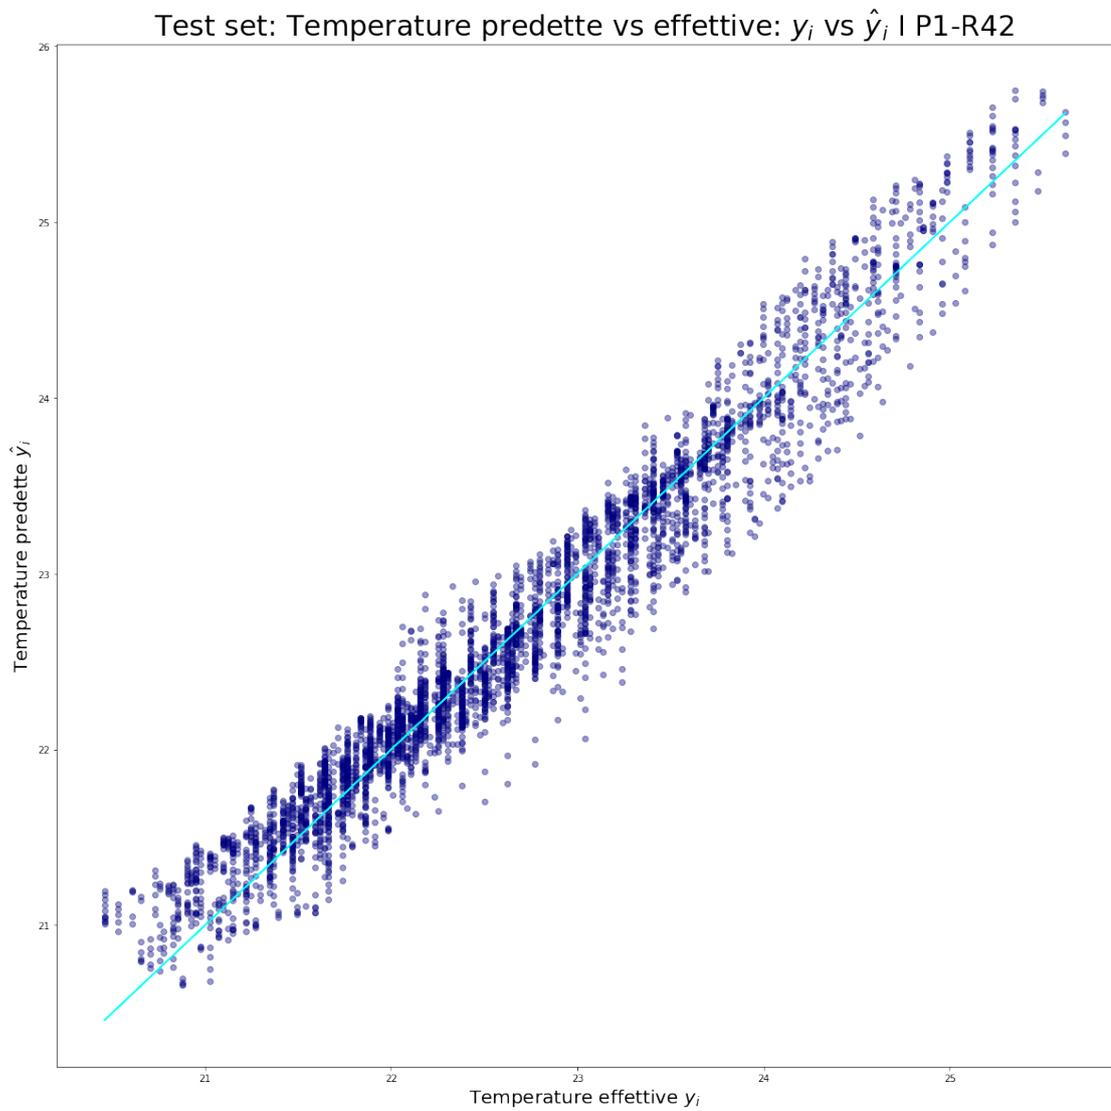


Figura 4.49: Temperature effettive vs predette - orizzonte di predizione di 2 ore - test set P1R42 - Approccio MIMO

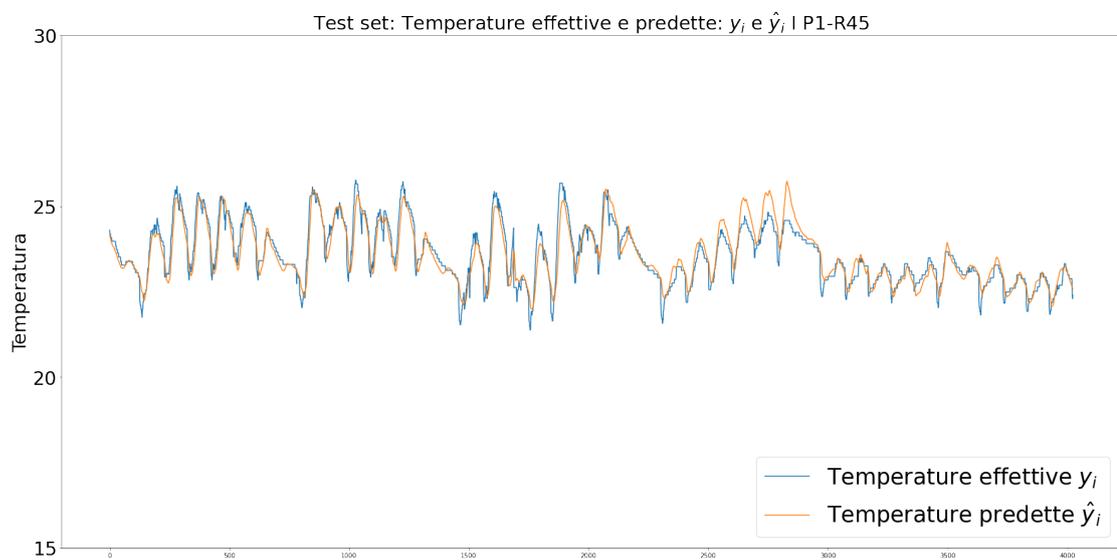


Figura 4.50: Temperature effettive e predette - orizzonte di predizione di 2 ore - test set P1R45 - Approccio MIMO

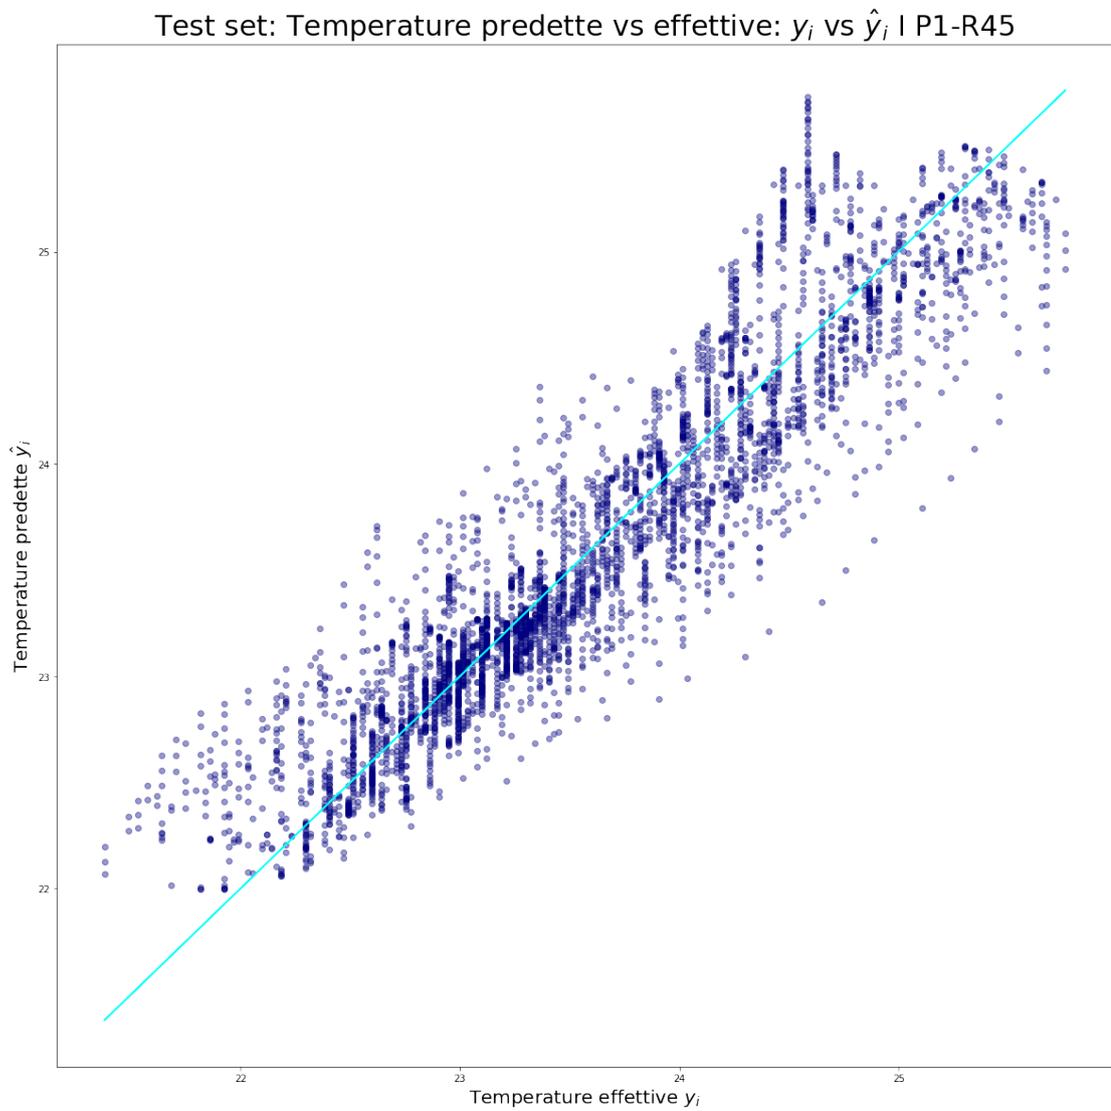


Figura 4.51: Temperature effettive vs predette - orizzonte di predizione di 2 ore - test set P1R45 - Approccio MIMO

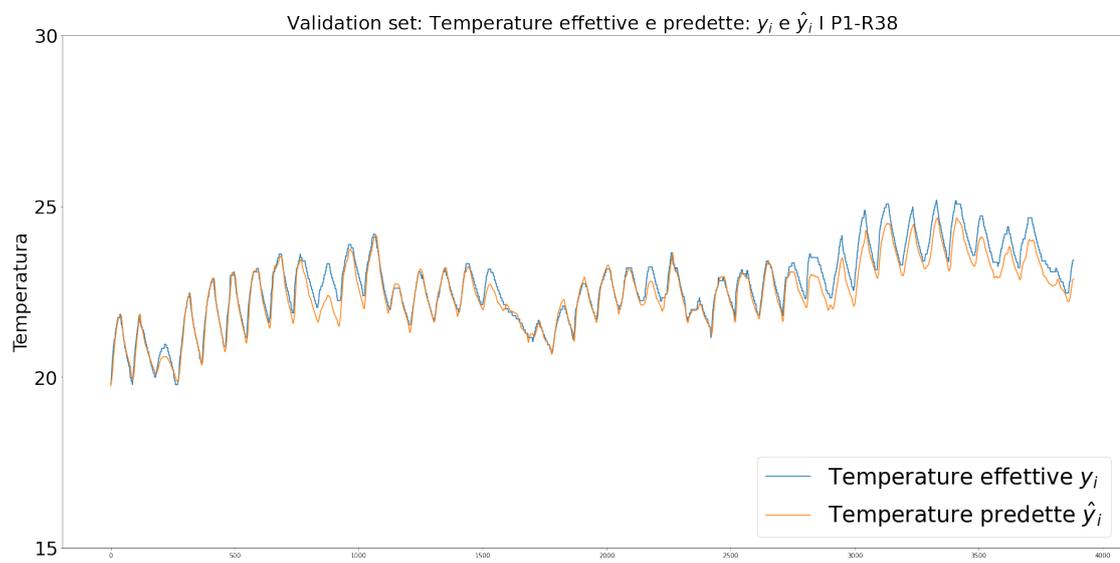


Figura 4.52: Temperature effettive e predette - orizzonte di predizione di 2 ore - validation set P1R38 - Approccio MIMO

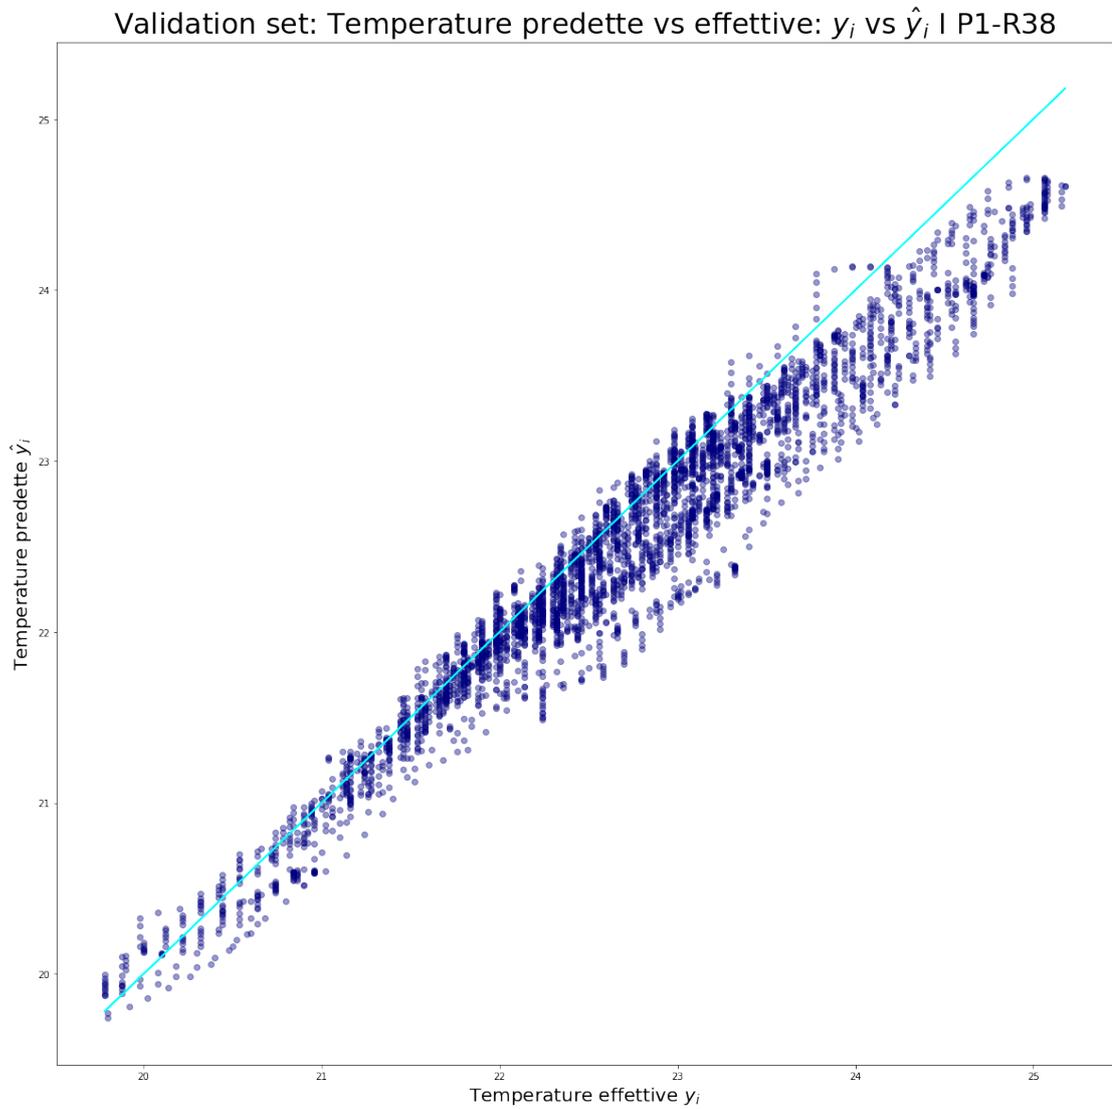


Figura 4.53: Temperature effettive vs predette - orizzonte di predizione di 2 ore - validation set P1R38 - Approccio MIMO

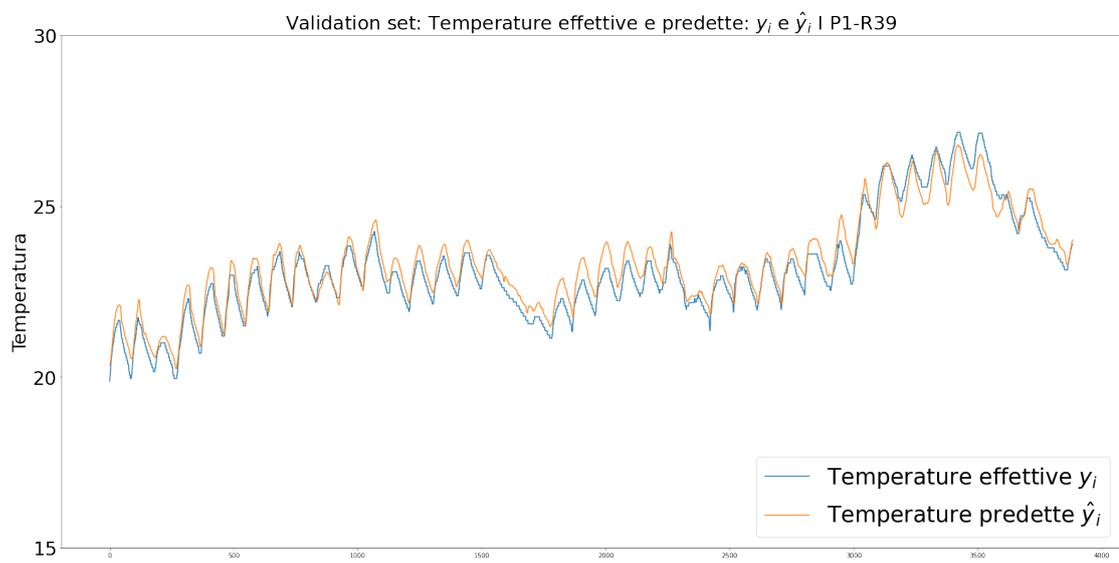


Figura 4.54: Temperature effettive e predette - orizzonte di predizione di 2 ore - validation set P1R39 - Approccio MIMO

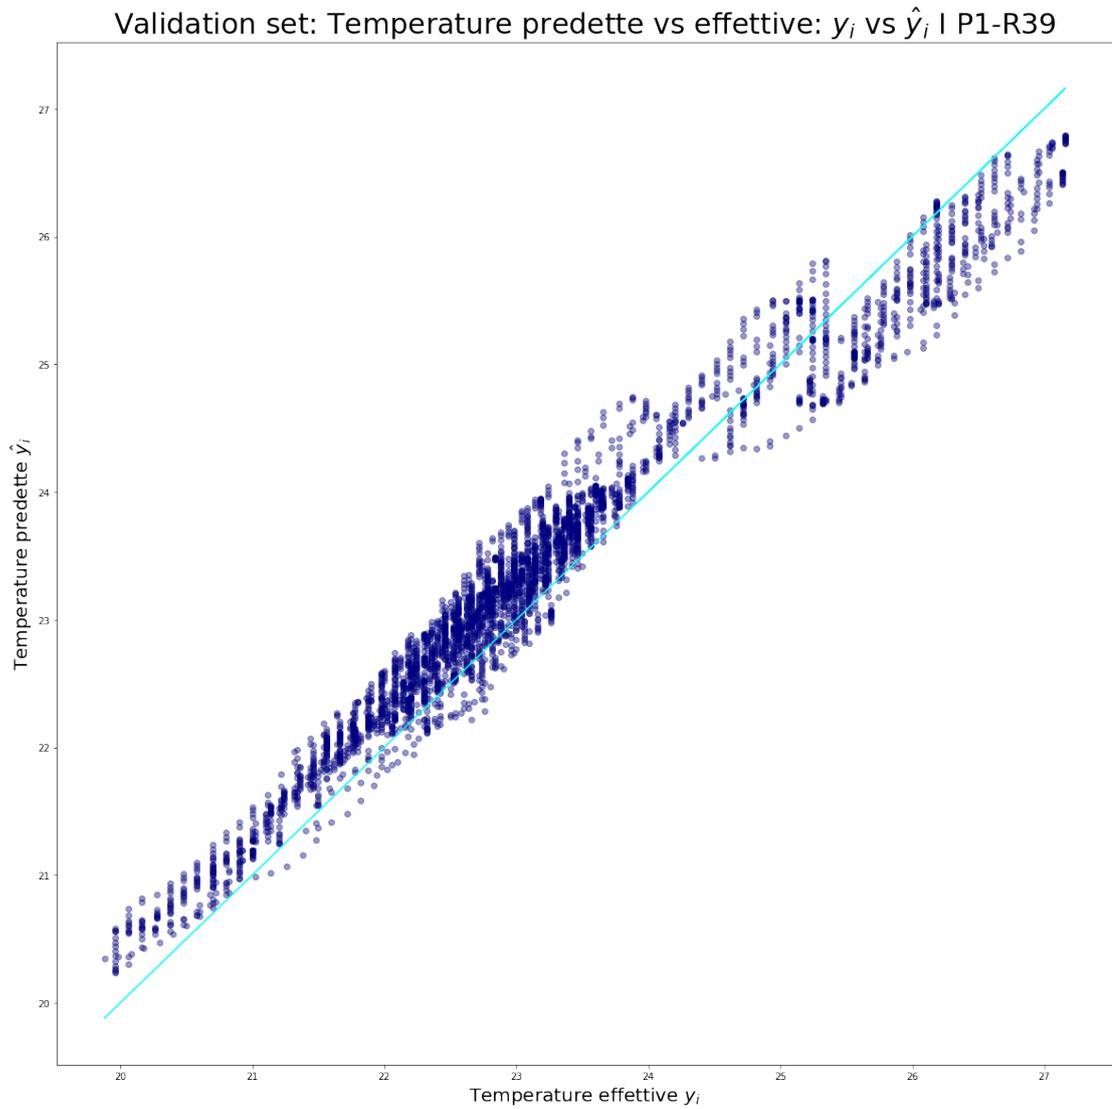


Figura 4.55: Temperature effettive vs predette - orizzonte di predizione di 2 ore - validation set P1R39 - Approccio MIMO

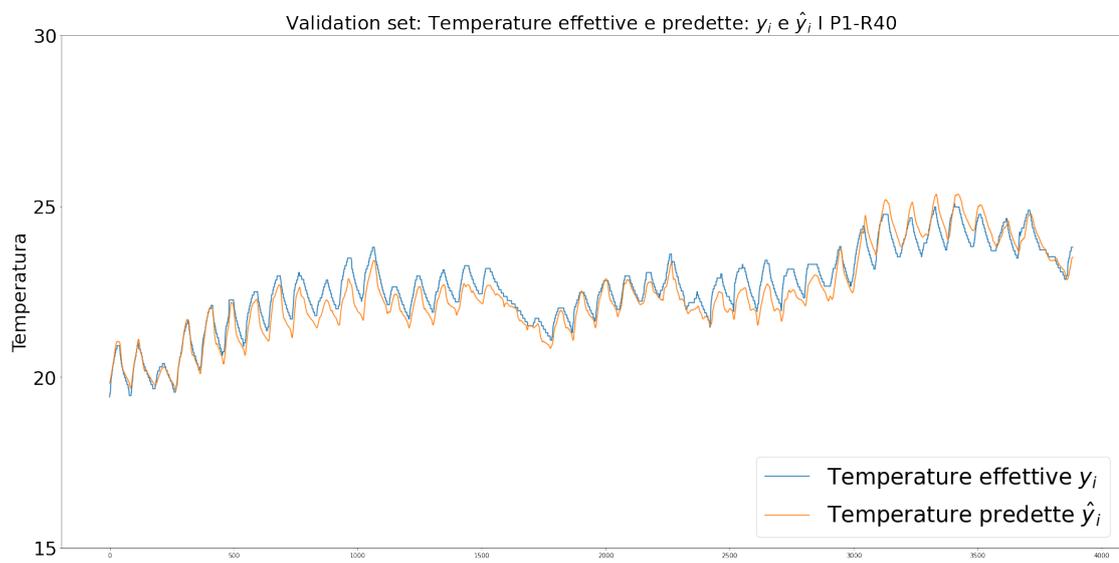


Figura 4.56: Temperature effettive e predette - orizzonte di predizione di 2 ore - validation set P1R40 - Approccio MIMO

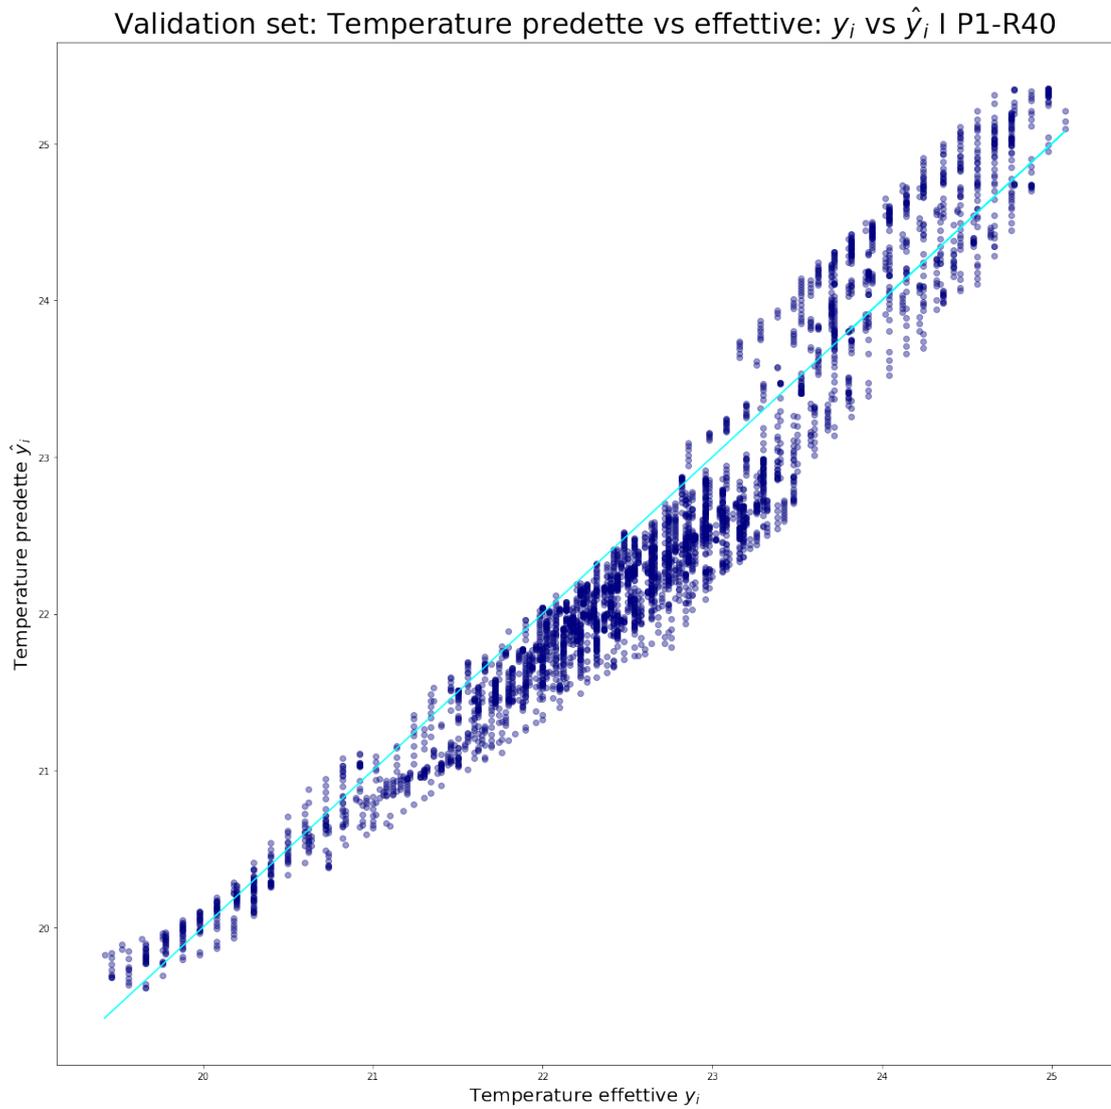


Figura 4.57: Temperature effettive vs predette - orizzonte di predizione di 2 ore - validation set P1R40 - Approccio MIMO

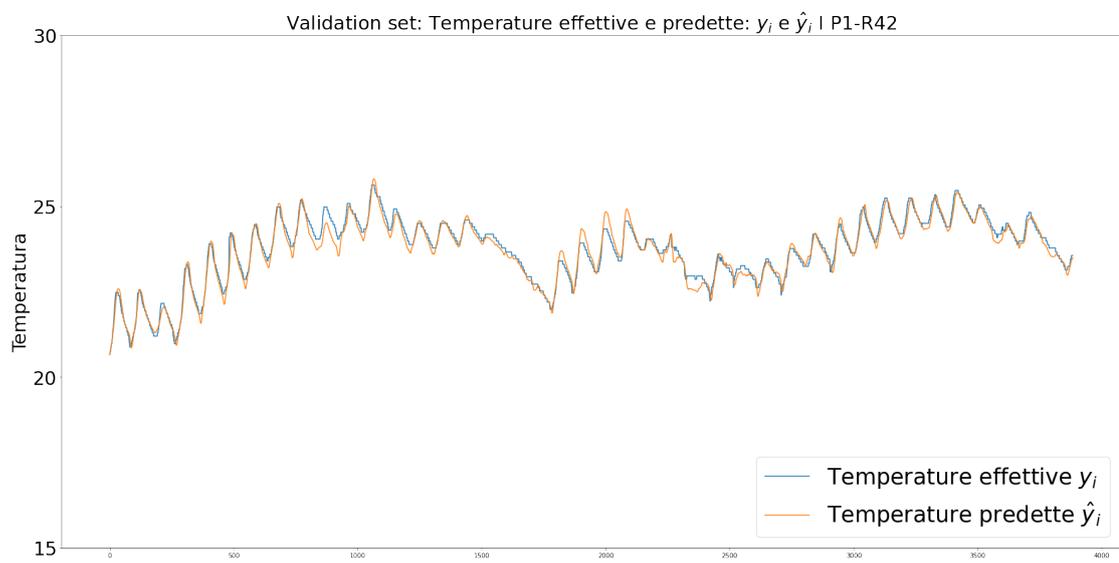


Figura 4.58: Temperature effettive e predette - orizzonte di predizione di 2 ore - validation set P1R42 - Approccio MIMO

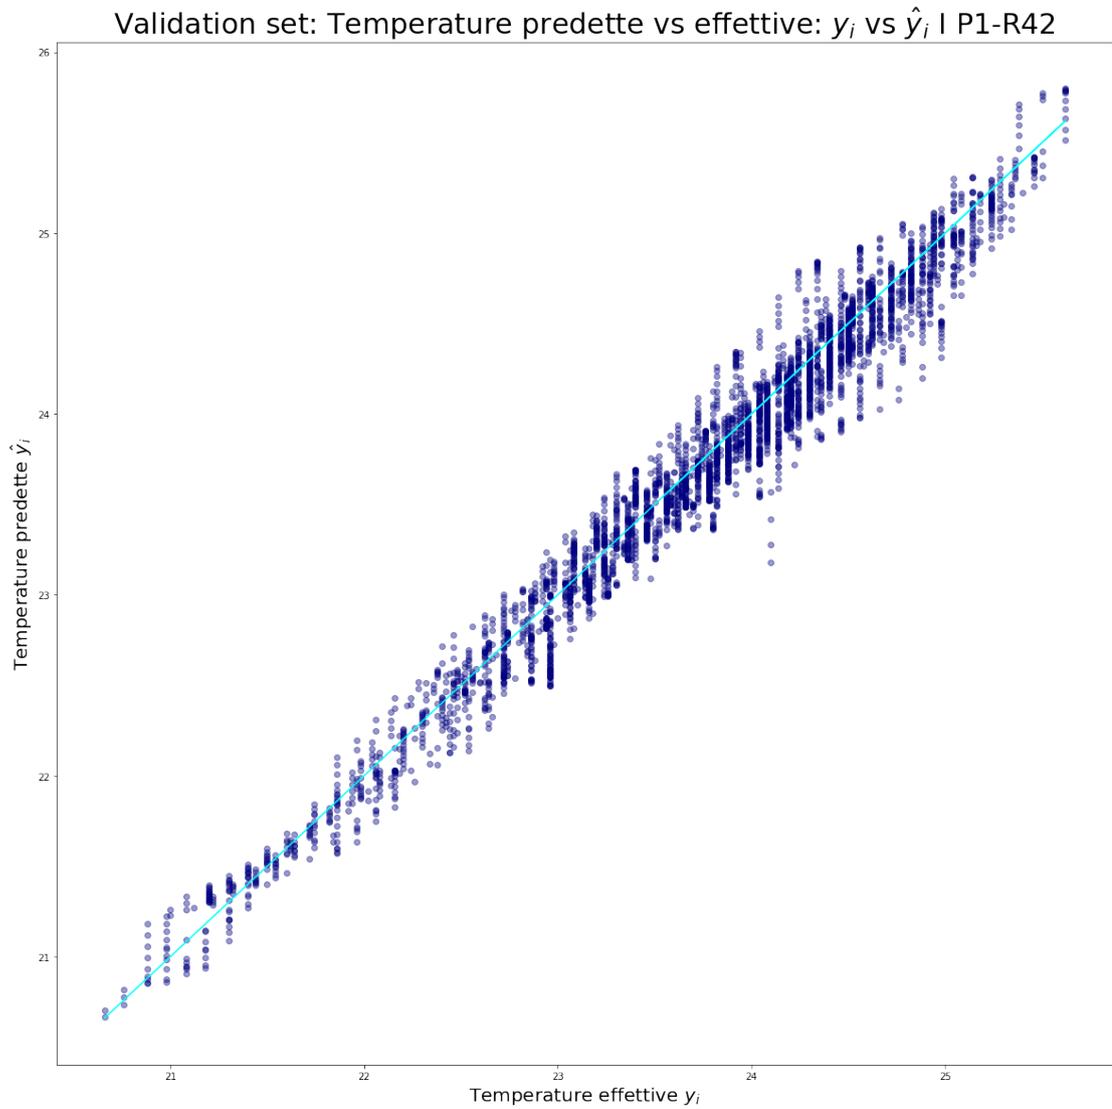


Figura 4.59: Temperature effettive vs predette - orizzonte di predizione di 2 ore - validation set P1R42 - Approccio MIMO

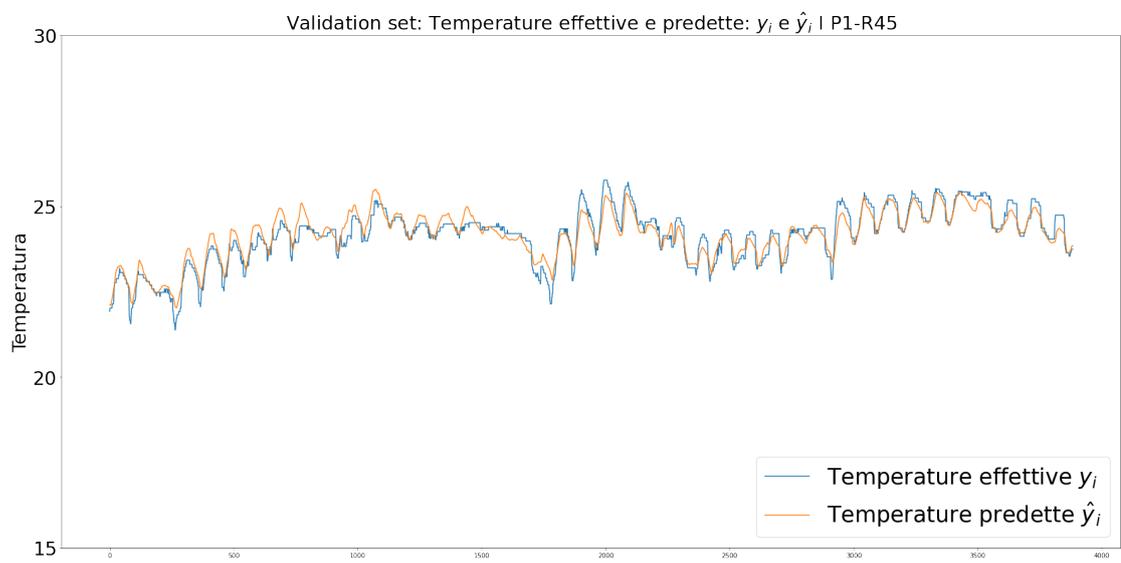


Figura 4.60: Temperature effettive e predette - orizzonte di predizione di 2 ore - validation set P1R45 - Approccio MIMO

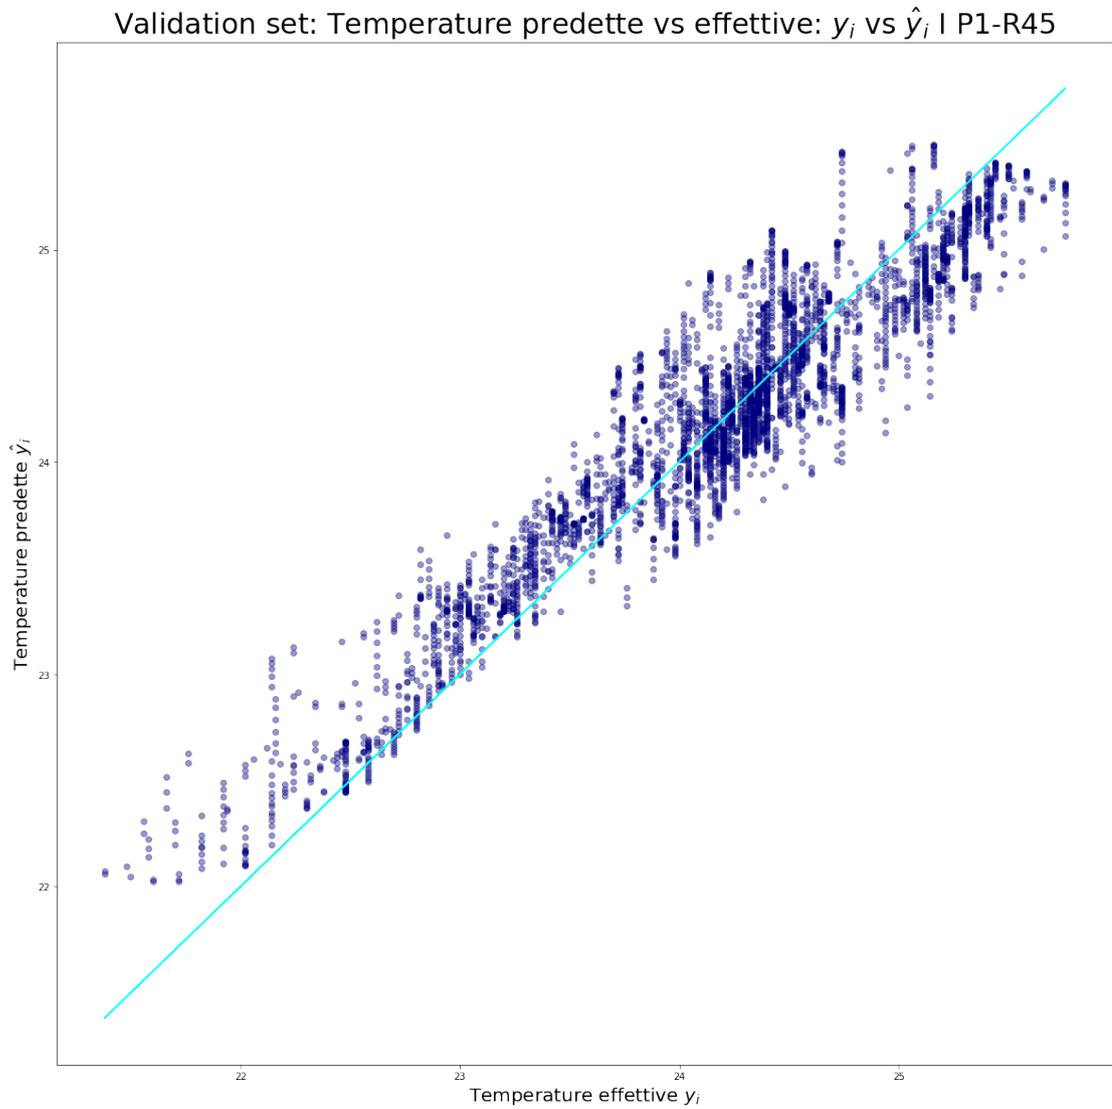


Figura 4.61: Temperature effettive vs predette - orizzonte di predizione di 2 ore - validation set P1R45 - Approccio MIMO

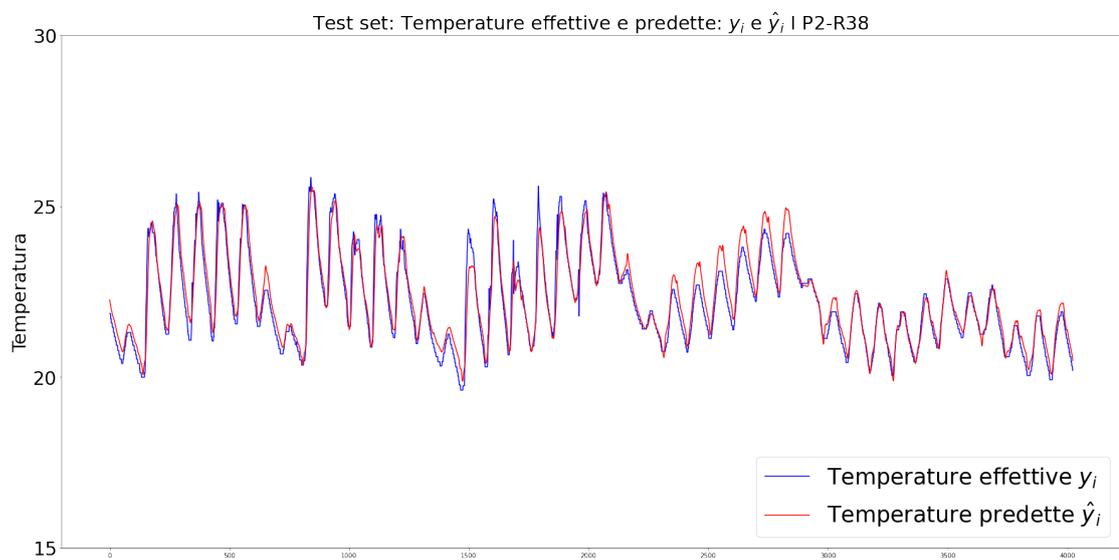


Figura 4.62: Temperature effettive e predette - orizzonte di predizione di 2 ore - test set P2R38 - Approccio MIMO

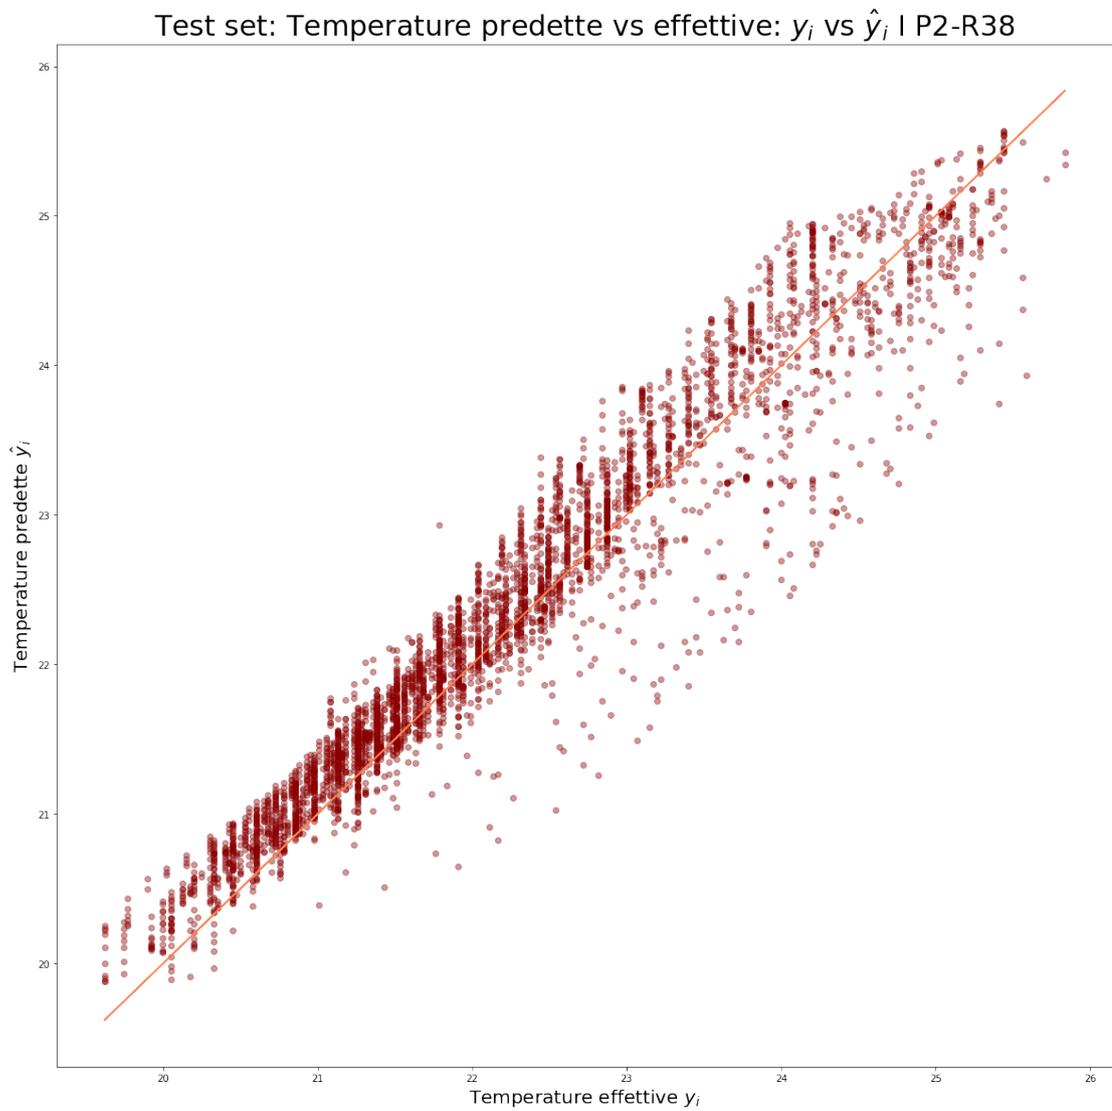


Figura 4.63: Temperature effettive vs predette - orizzonte di predizione di 2 ore - test set P2R38 - Approccio MIMO

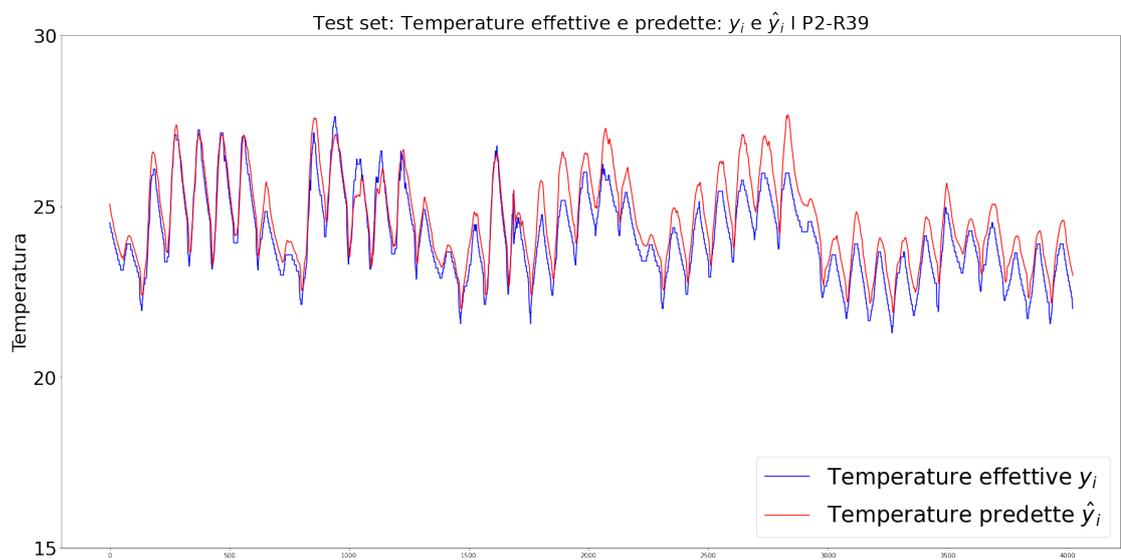


Figura 4.64: Temperature effettive e predette - orizzonte di predizione di 2 ore - test set P2R39 - Approccio MIMO

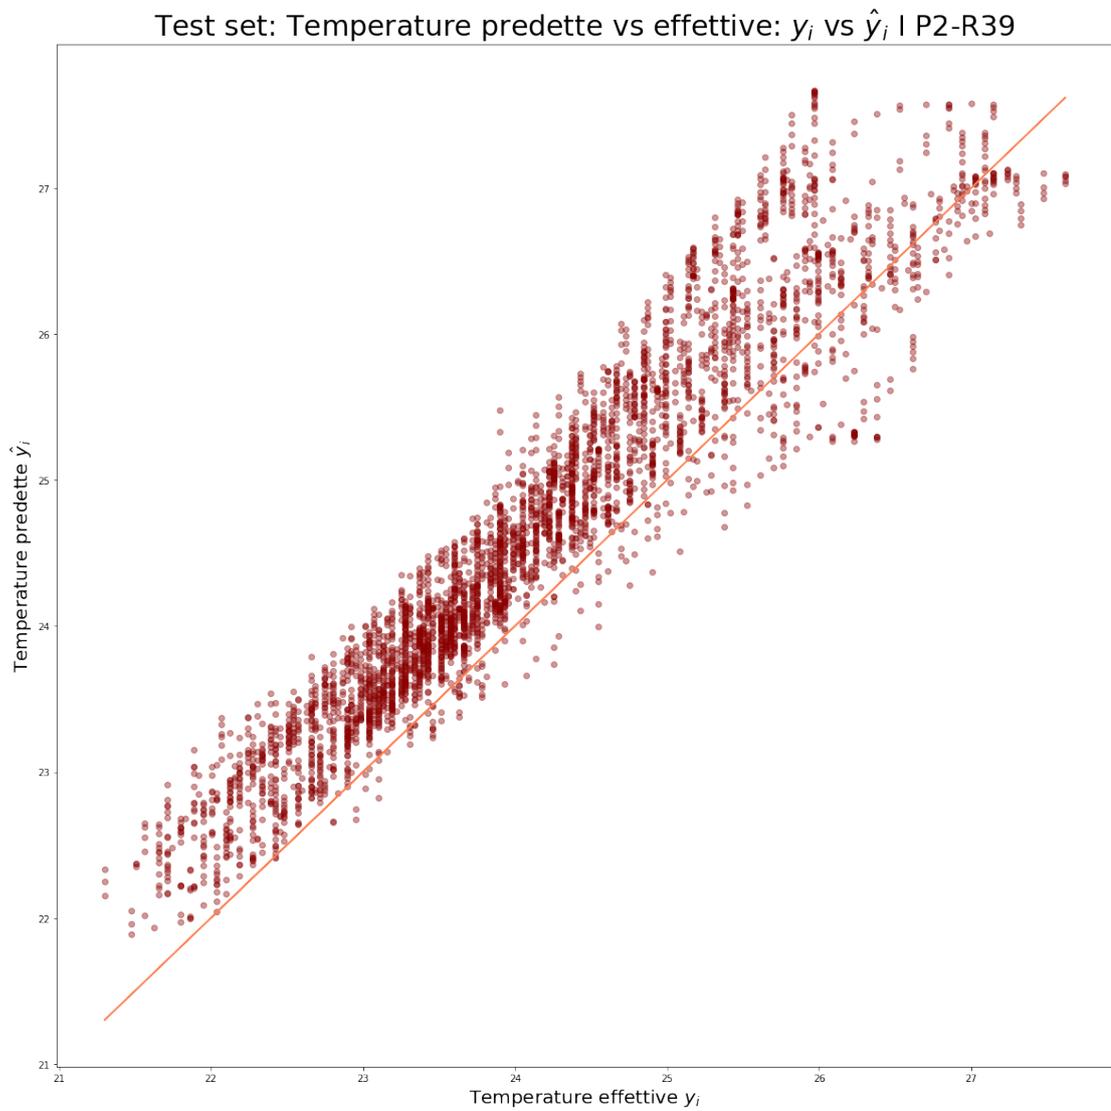


Figura 4.65: Temperature effettive vs predette - orizzonte di predizione di 2 ore - test set P2R39 - Approccio MIMO

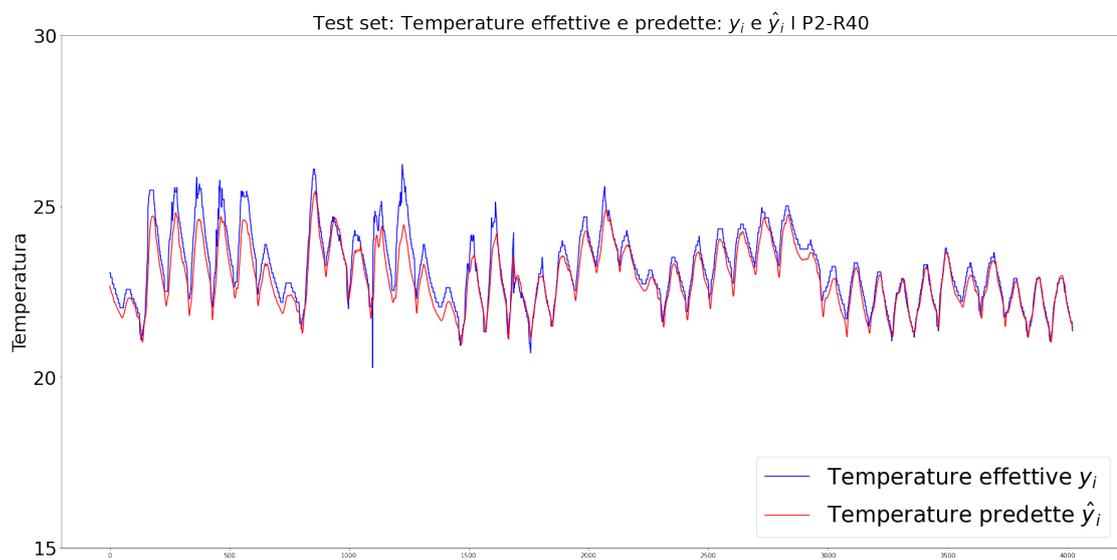


Figura 4.66: Temperature effettive e predette - orizzonte di predizione di 2 ore - test set P2R40 - Approccio MIMO

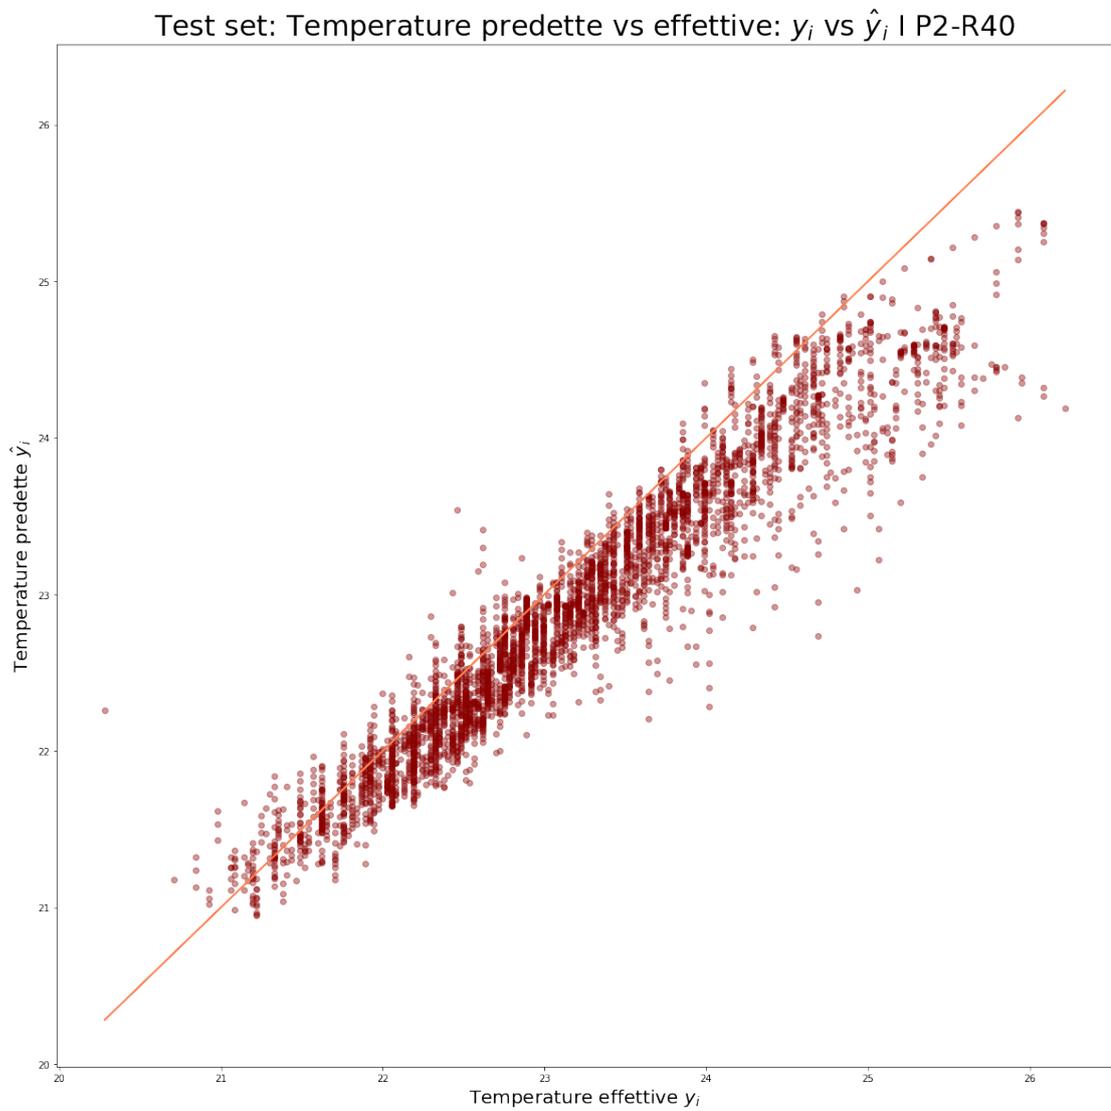


Figura 4.67: Temperature effettive vs predette - orizzonte di predizione di 2 ore - test set P2R40 - Approccio MIMO

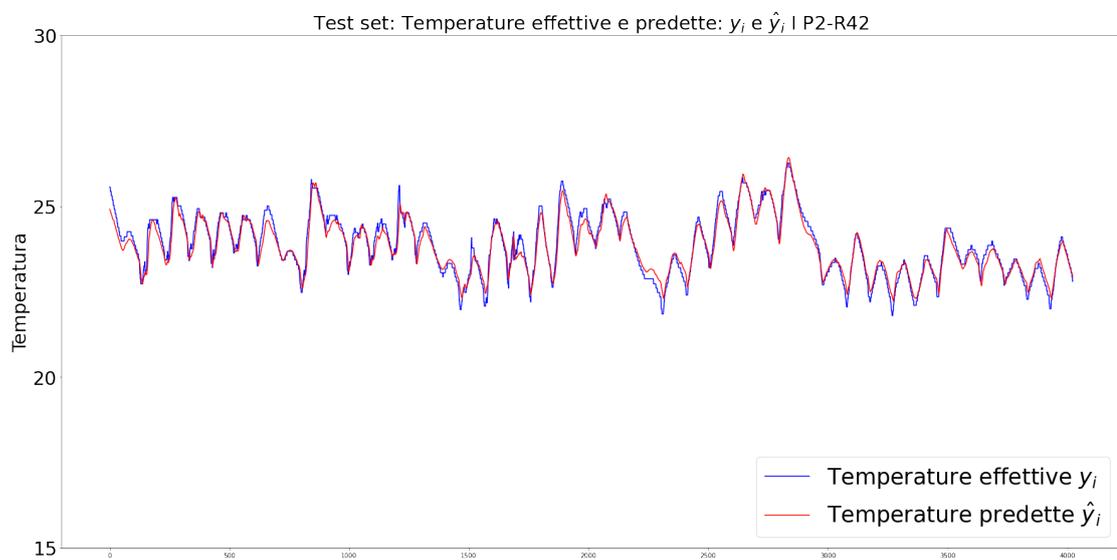


Figura 4.68: Temperature effettive e predette - orizzonte di predizione di 2 ore - test set P2R42 - Approccio MIMO

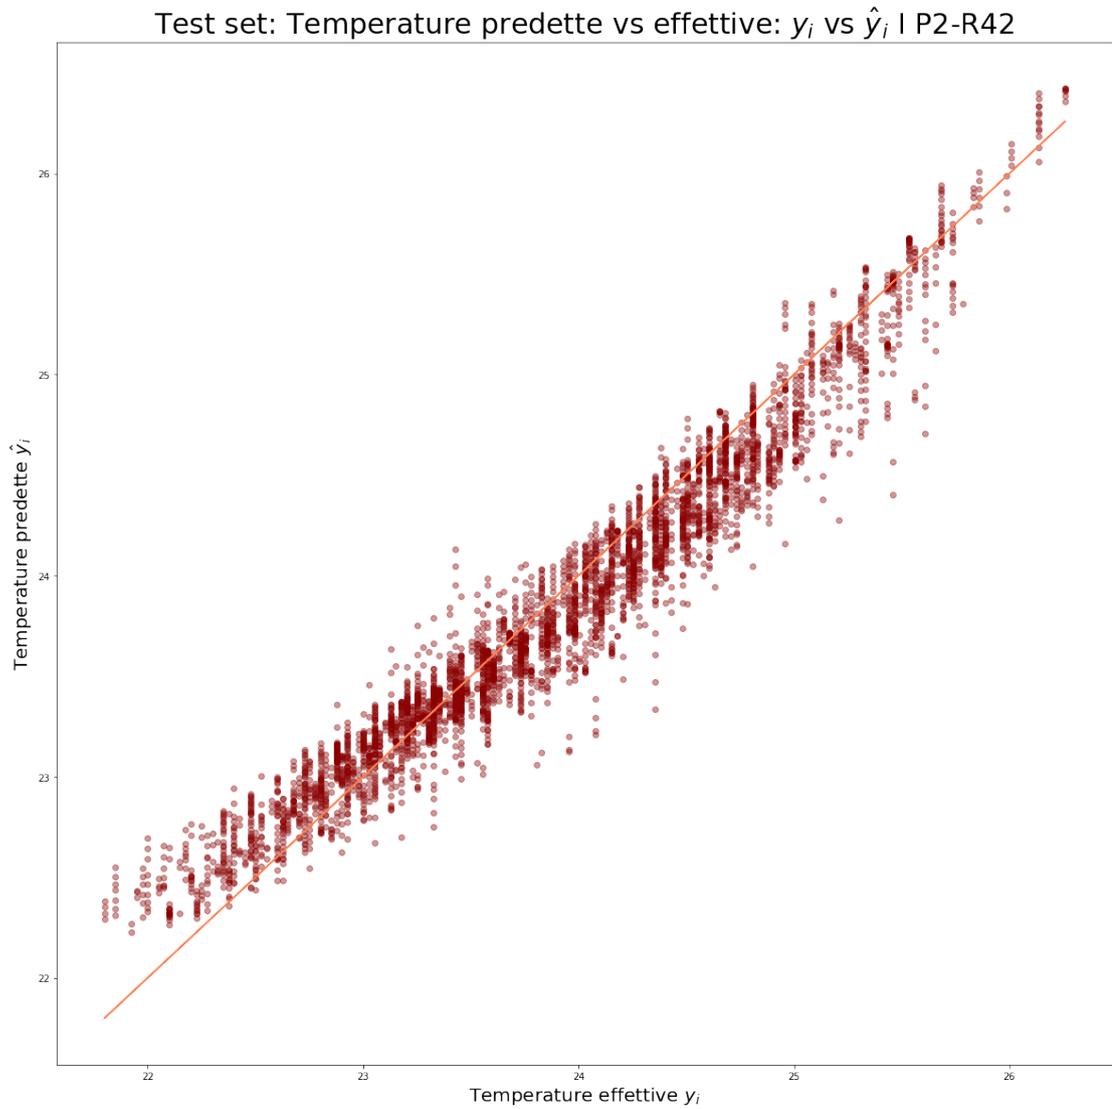


Figura 4.69: Temperature effettive vs predette - orizzonte di predizione di 2 ore - test set P2R42 - Approccio MIMO

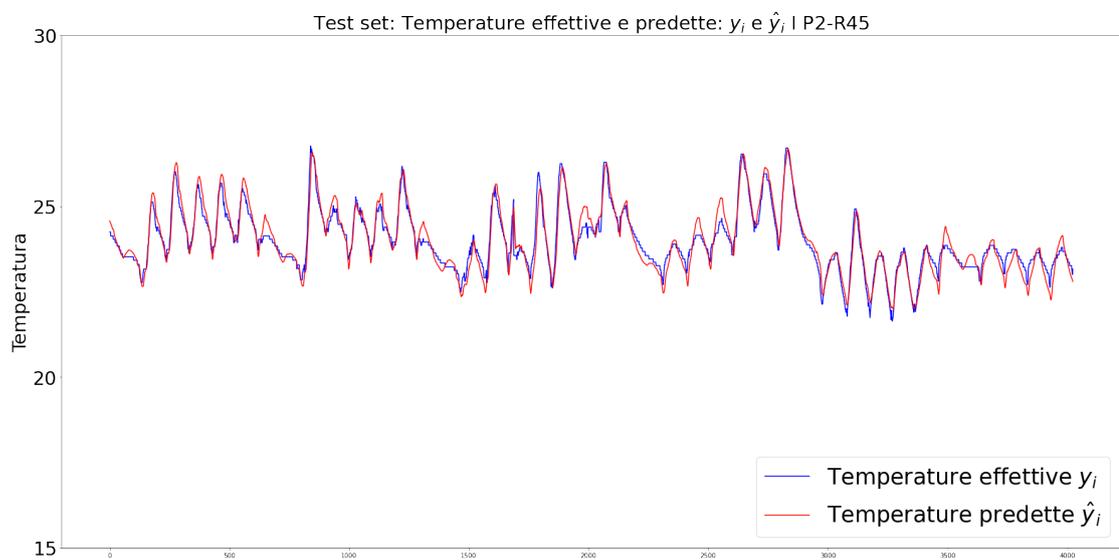


Figura 4.70: Temperature effettive e predette - orizzonte di predizione di 2 ore - test set P2R45 - Approccio MIMO

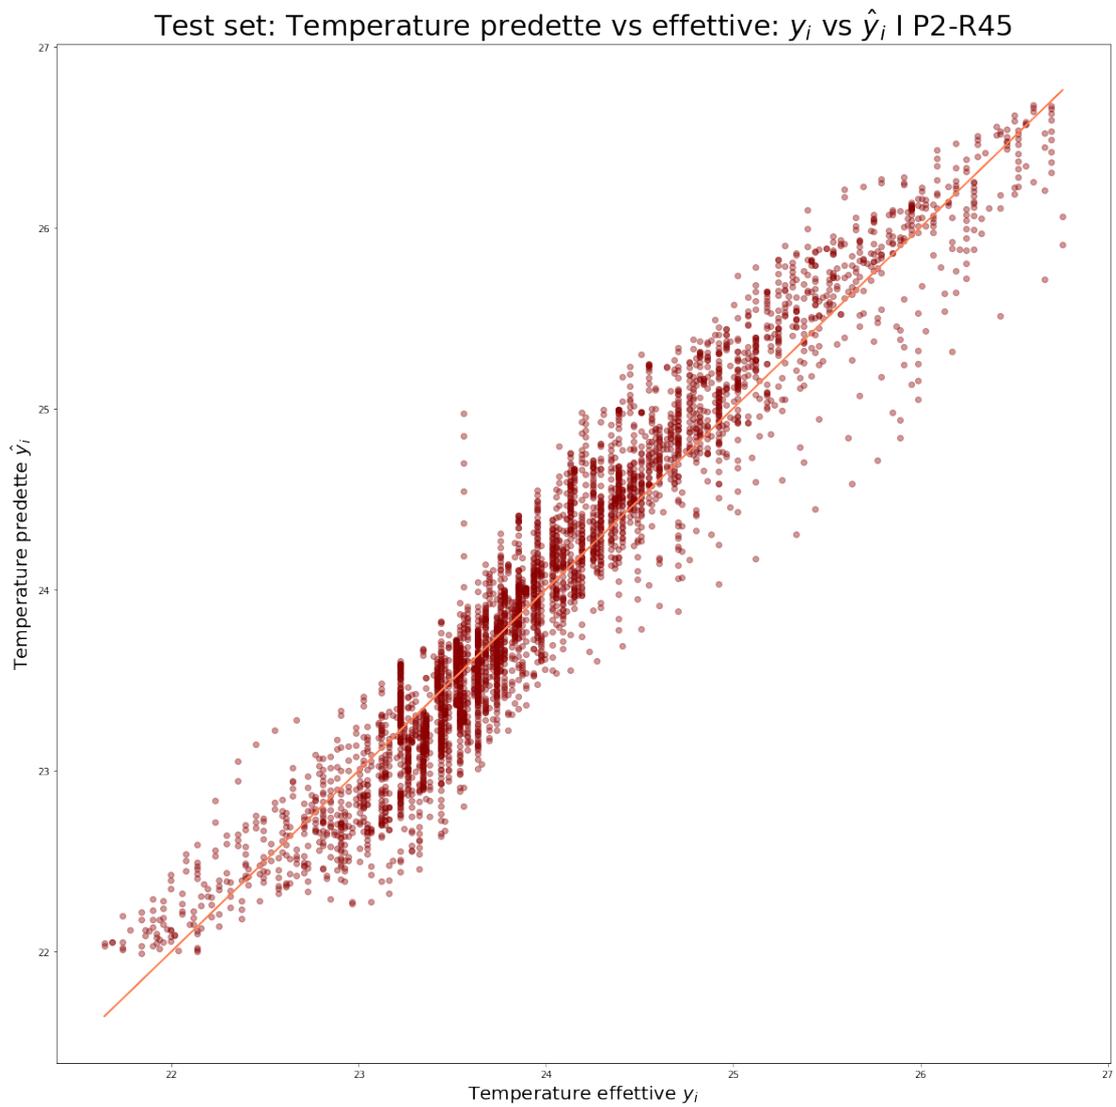


Figura 4.71: Temperature effettive vs predette - orizzonte di predizione di 2 ore - test set P2R45 - Approccio MIMO

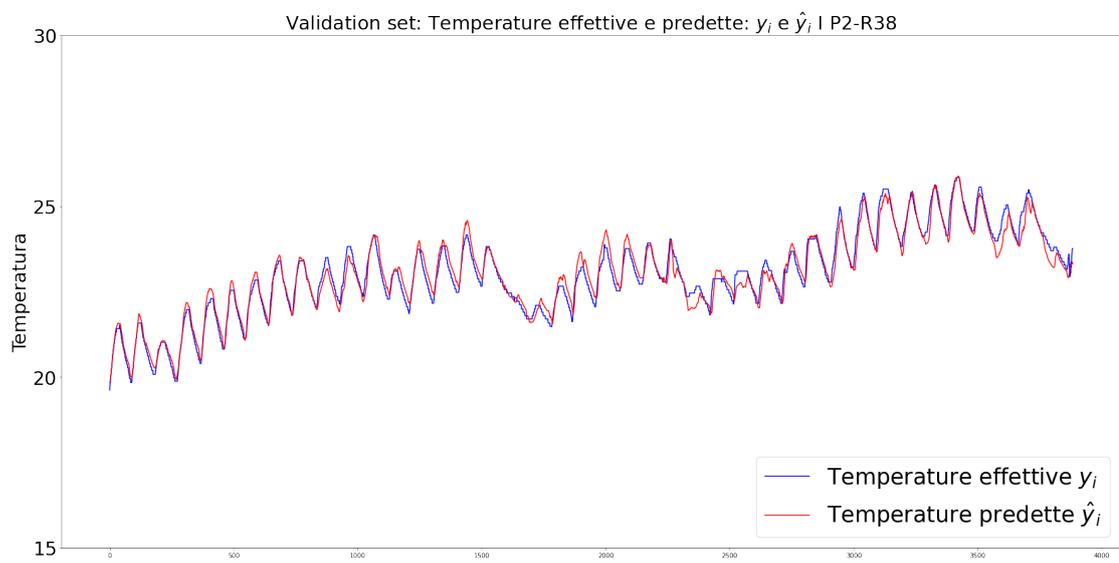


Figura 4.72: Temperature effettive e predette - orizzonte di predizione di 2 ore - validation set P2R38 - Approccio MIMO

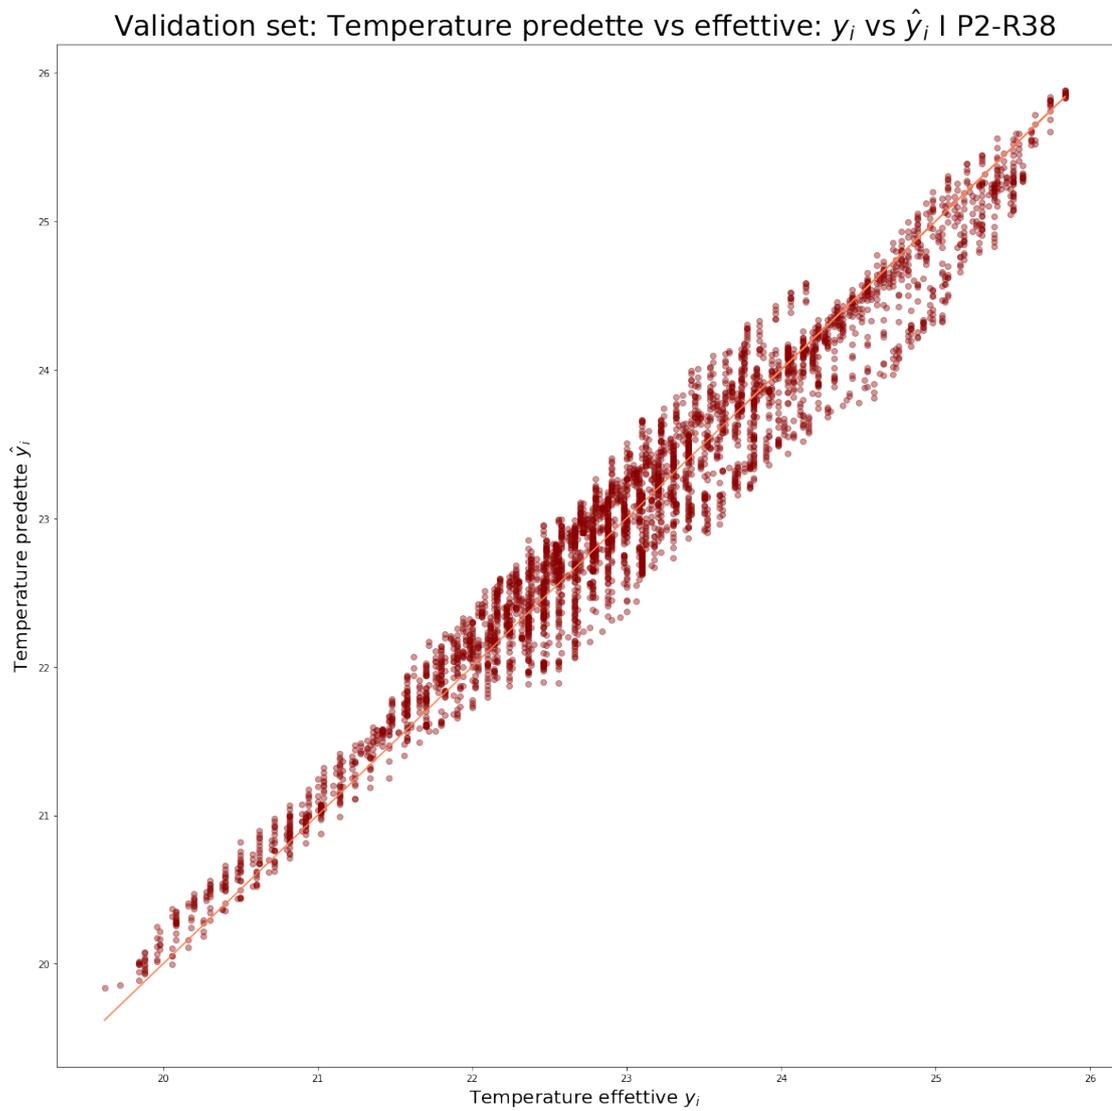


Figura 4.73: Temperature effettive vs predette - orizzonte di predizione di 2 ore - validation set P2R38 - Approccio MIMO

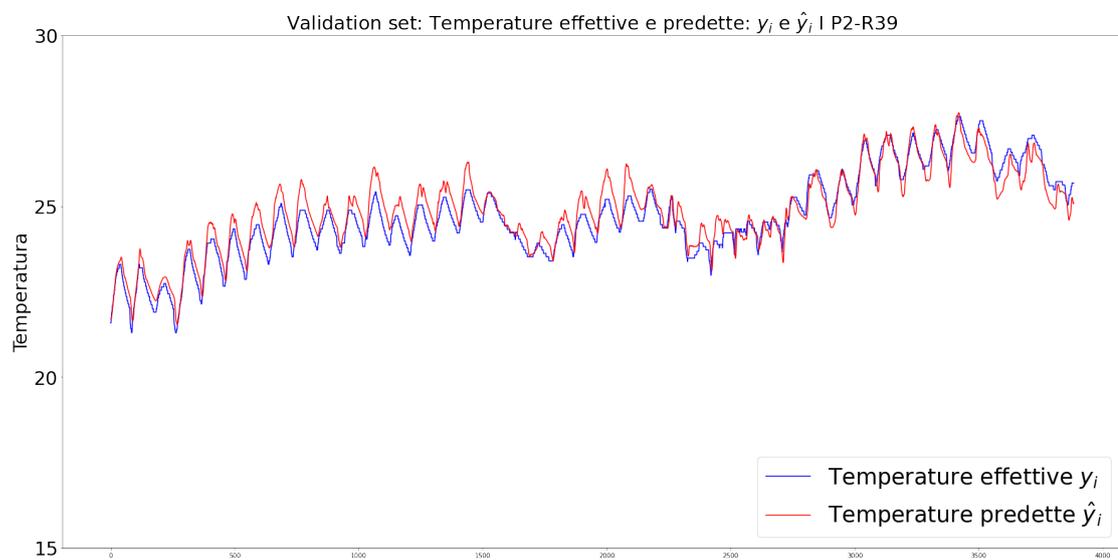


Figura 4.74: Temperature effettive e predette - orizzonte di predizione di 2 ore - validation set P2R39 - Approccio MIMO

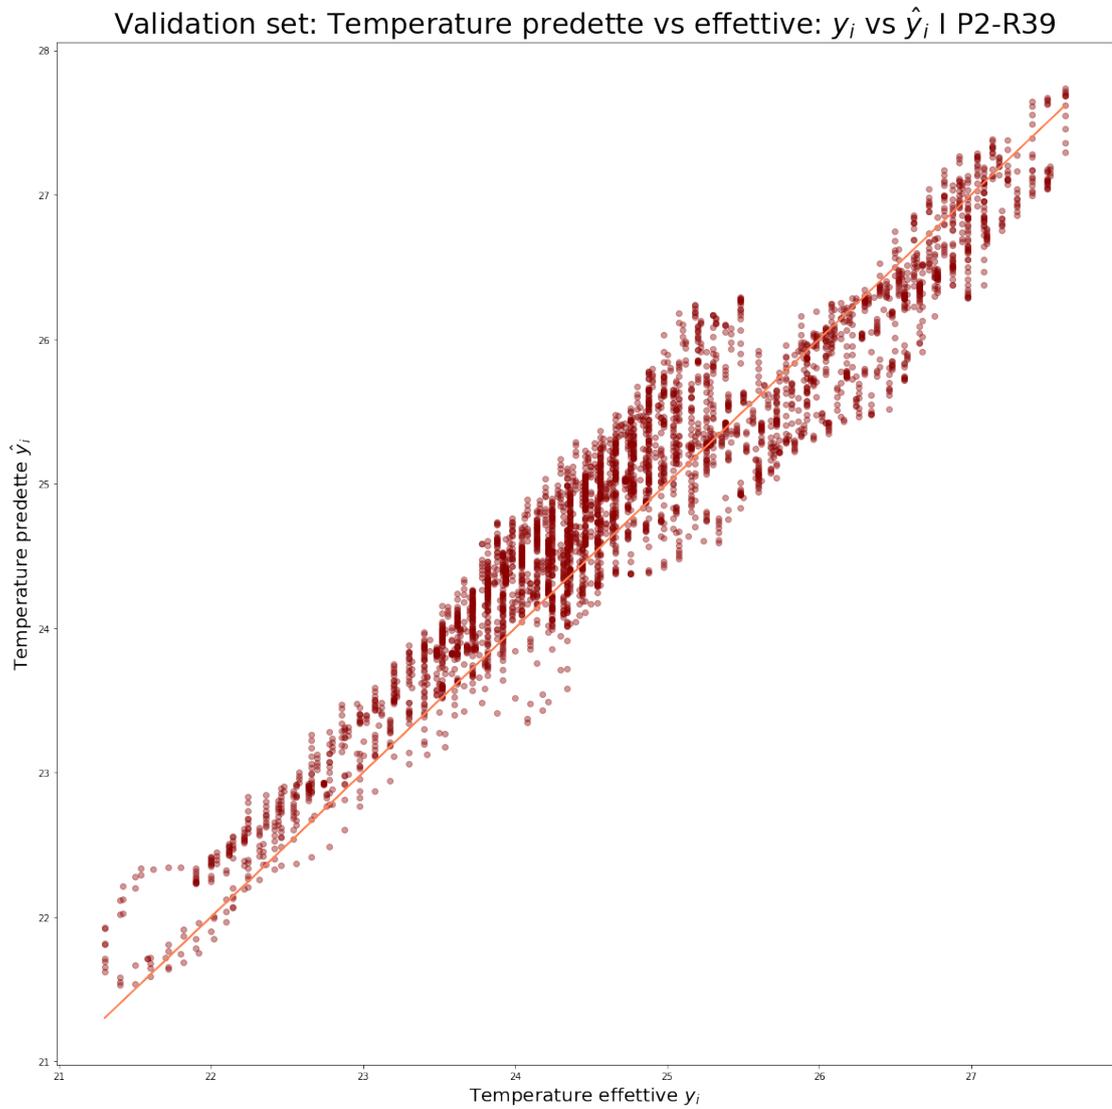


Figura 4.75: Temperature effettive vs predette - orizzonte di predizione di 2 ore - validation set P2R39 - Approccio MIMO

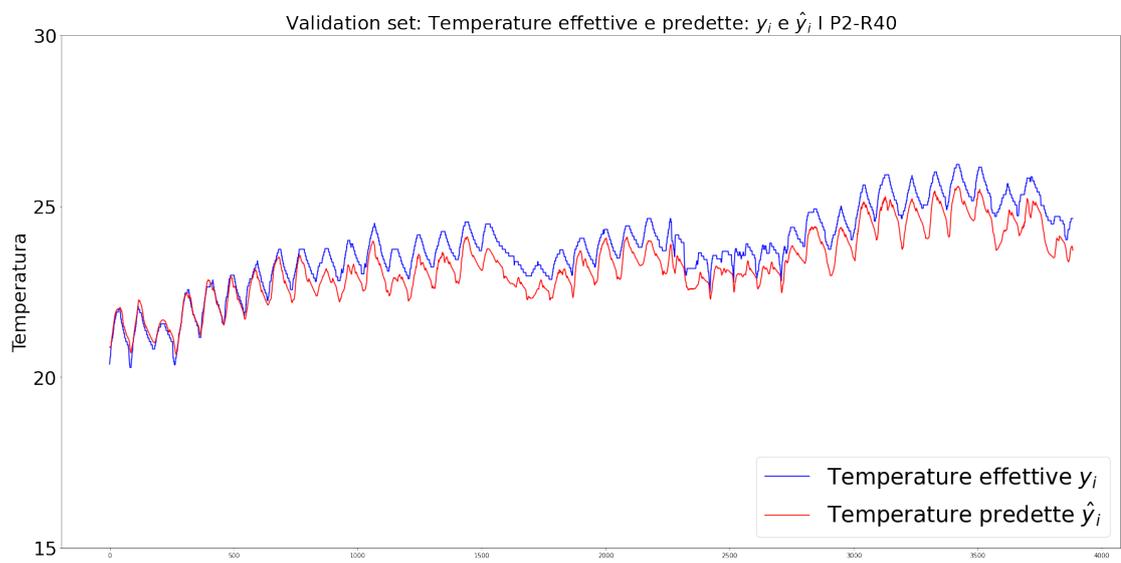


Figura 4.76: Temperature effettive e predette - orizzonte di predizione di 2 ore - validation set P2R40 - Approccio MIMO

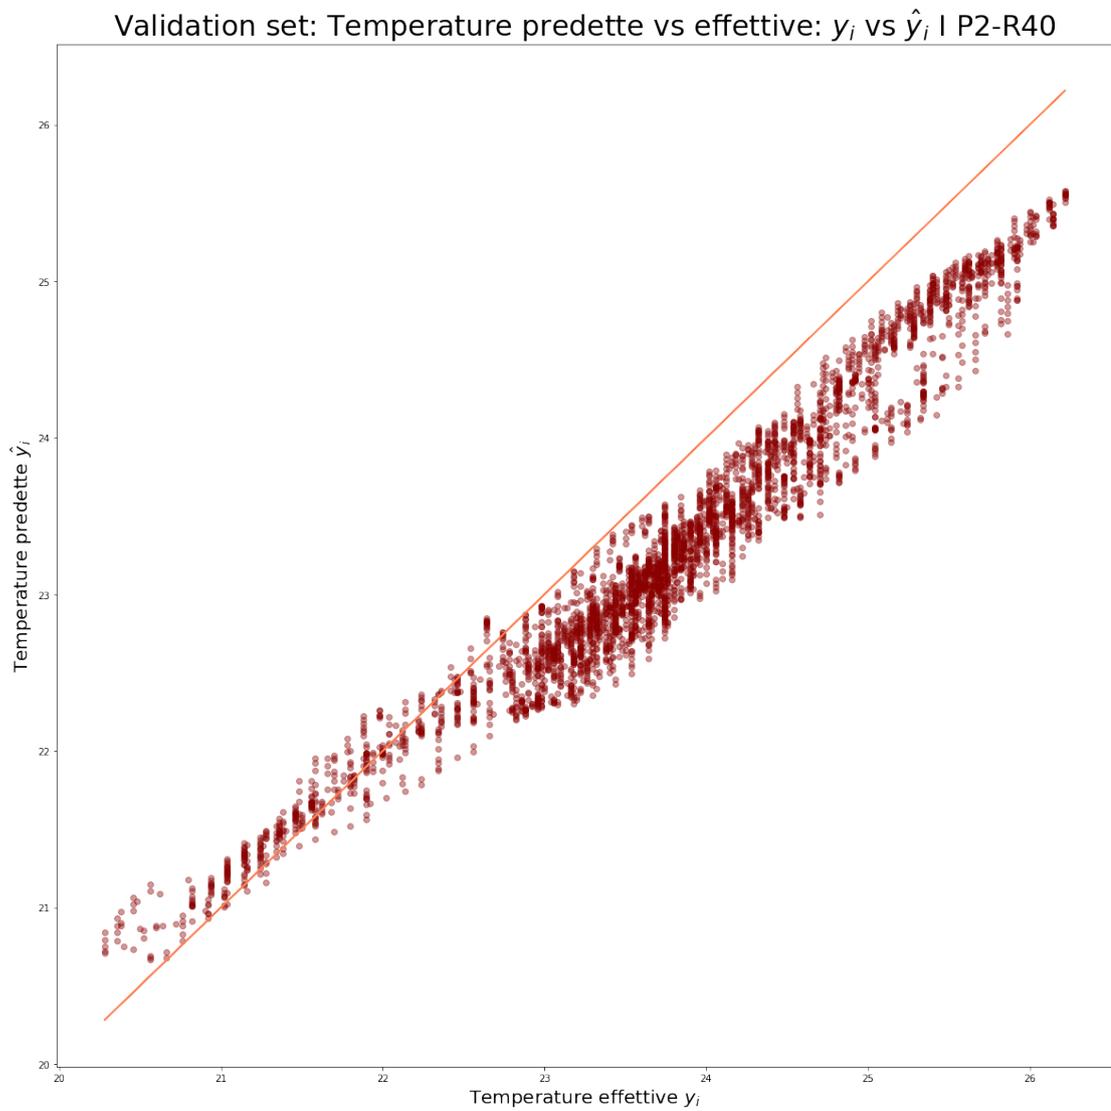


Figura 4.77: Temperature effettive vs predette - orizzonte di predizione di 2 ore - validation set P2R40 - Approccio MIMO

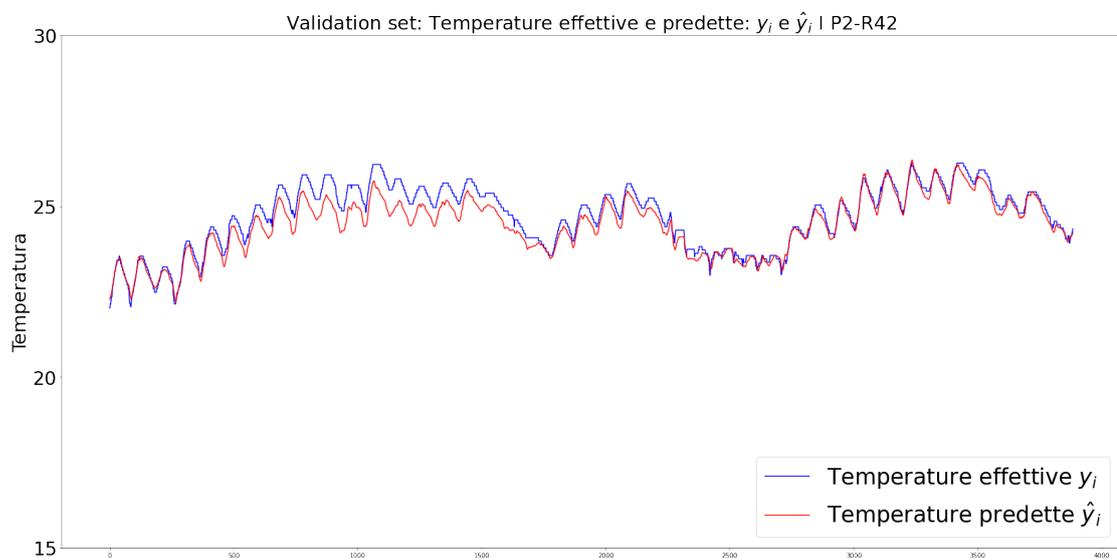


Figura 4.78: Temperature effettive e predette - orizzonte di predizione di 2 ore - validation set P2R42 - Approccio MIMO

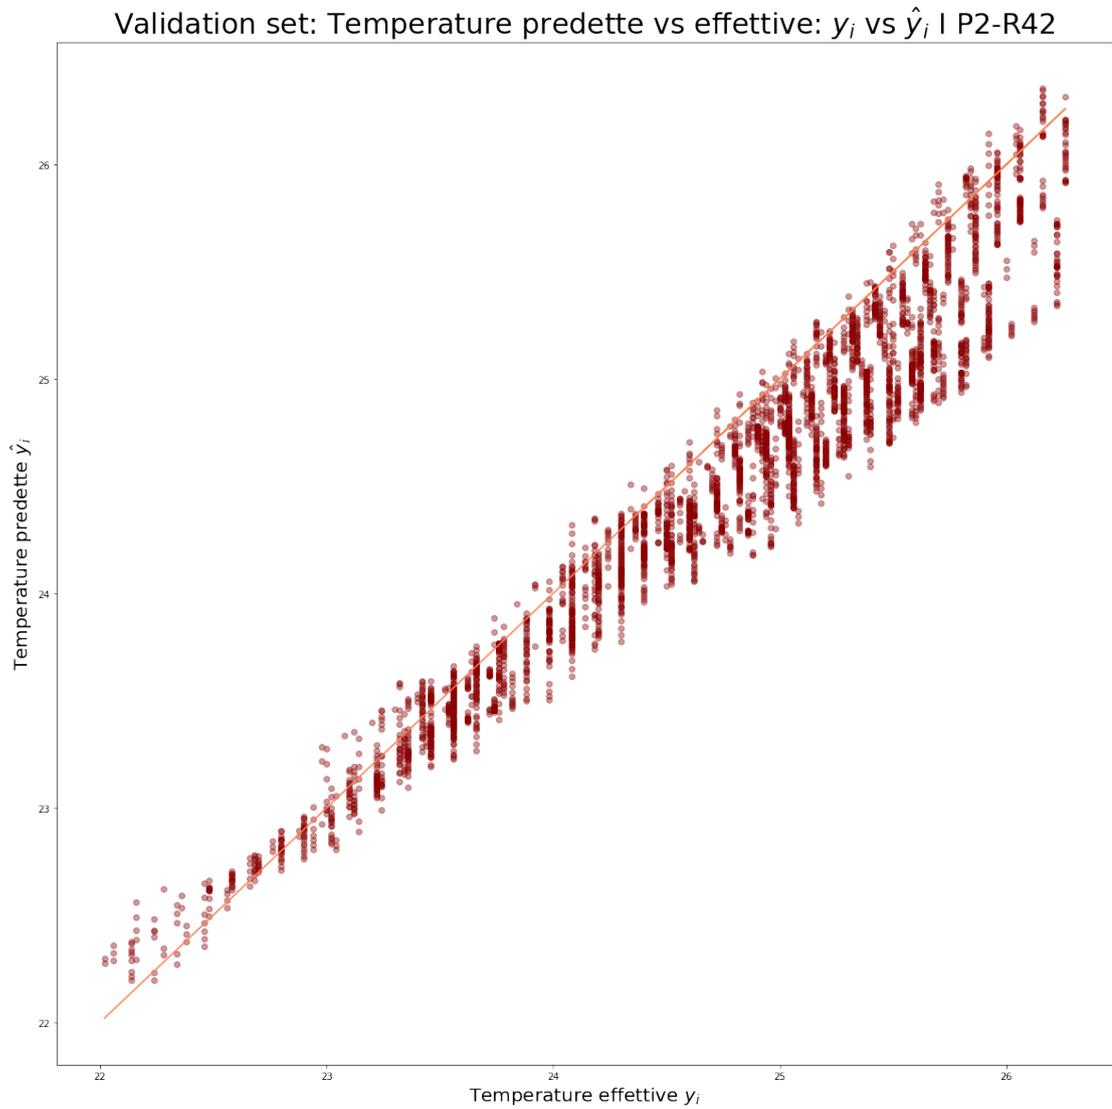


Figura 4.79: Temperature effettive vs predette - orizzonte di predizione di 2 ore - validation set P2R42 - Approccio MIMO

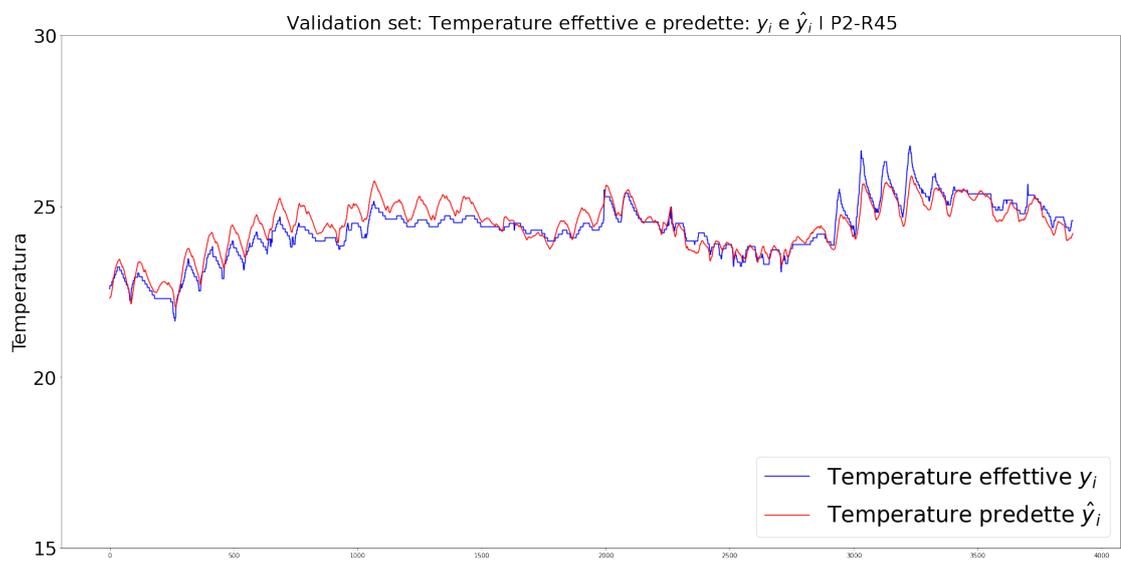


Figura 4.80: Temperature effettive e predette - orizzonte di predizione di 2 ore - validation set P2R45 - Approccio MIMO

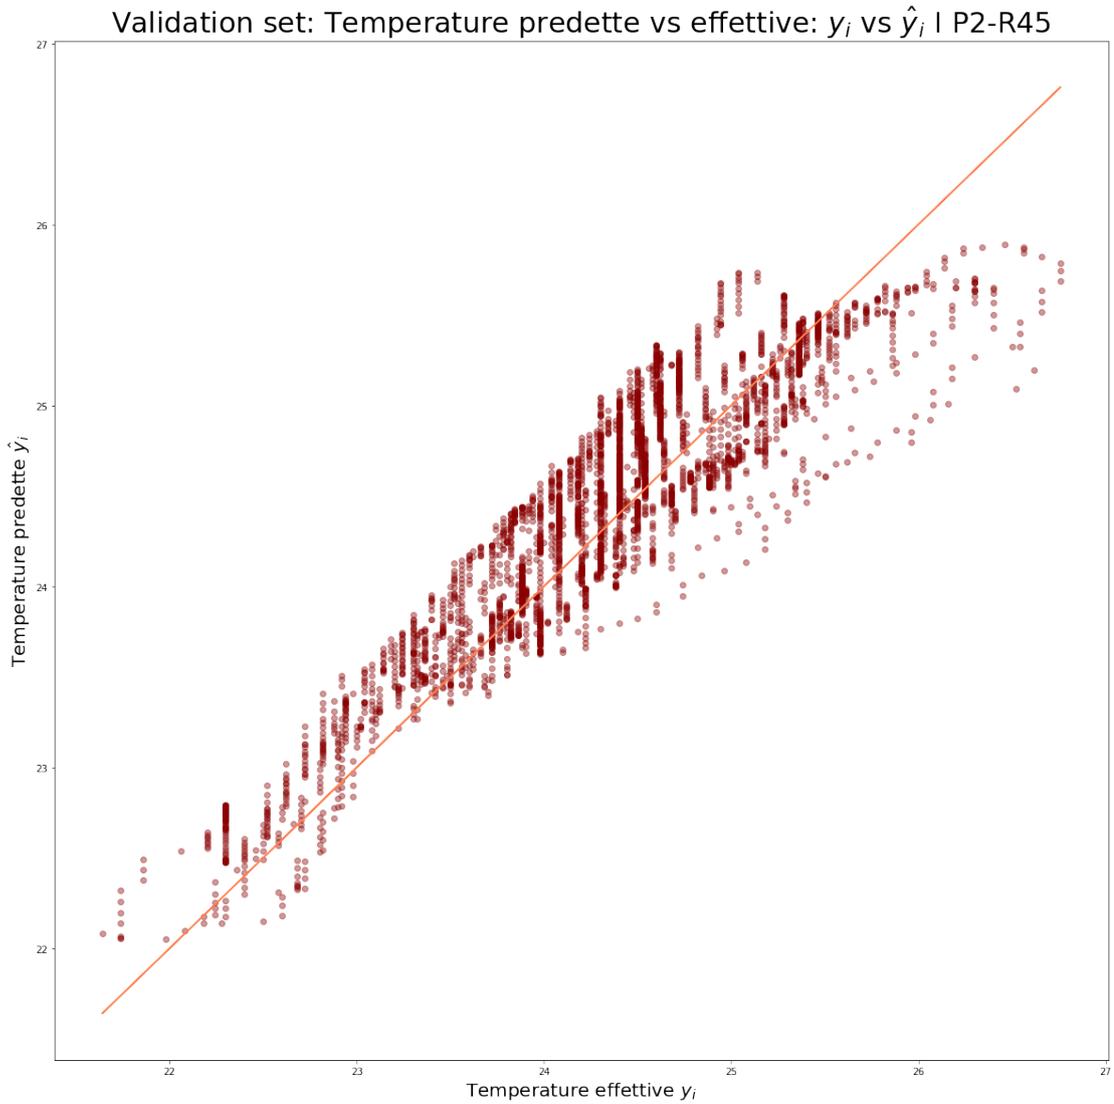


Figura 4.81: Temperature effettive vs predette - orizzonte di predizione di 2 ore - validation set P2R45 - Approccio MIMO

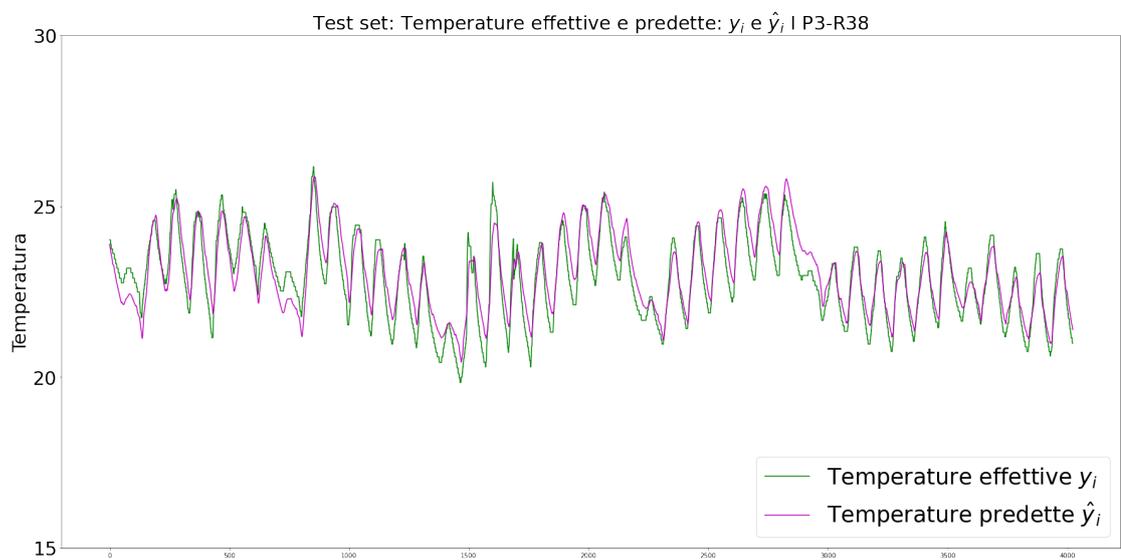


Figura 4.82: Temperature effettive e predette - orizzonte di predizione di 2 ore - test set P3R38 - Approccio MIMO

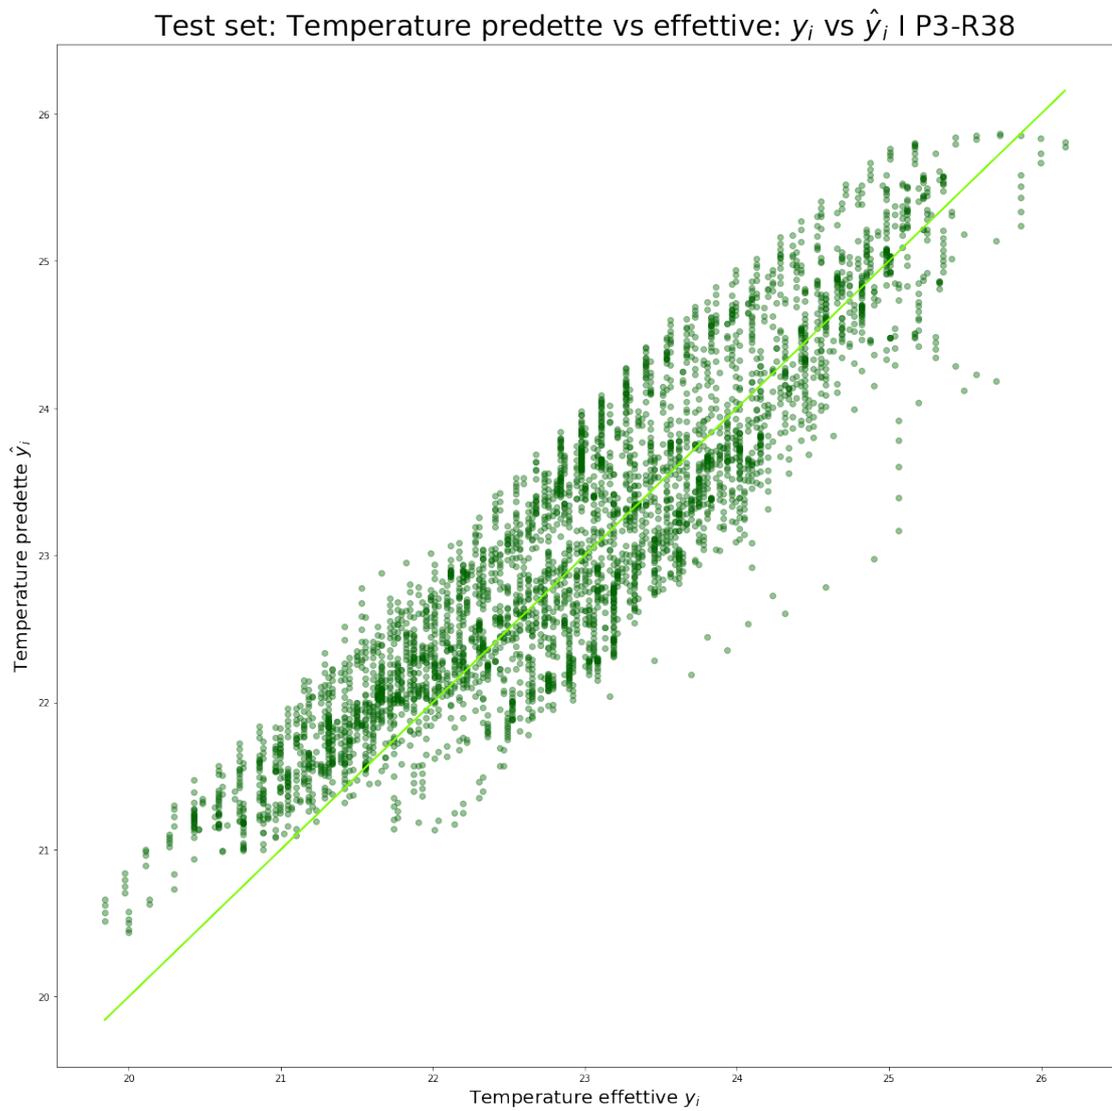


Figura 4.83: Temperature effettive vs predette - orizzonte di predizione di 2 ore - test set P3R38 - Approccio MIMO

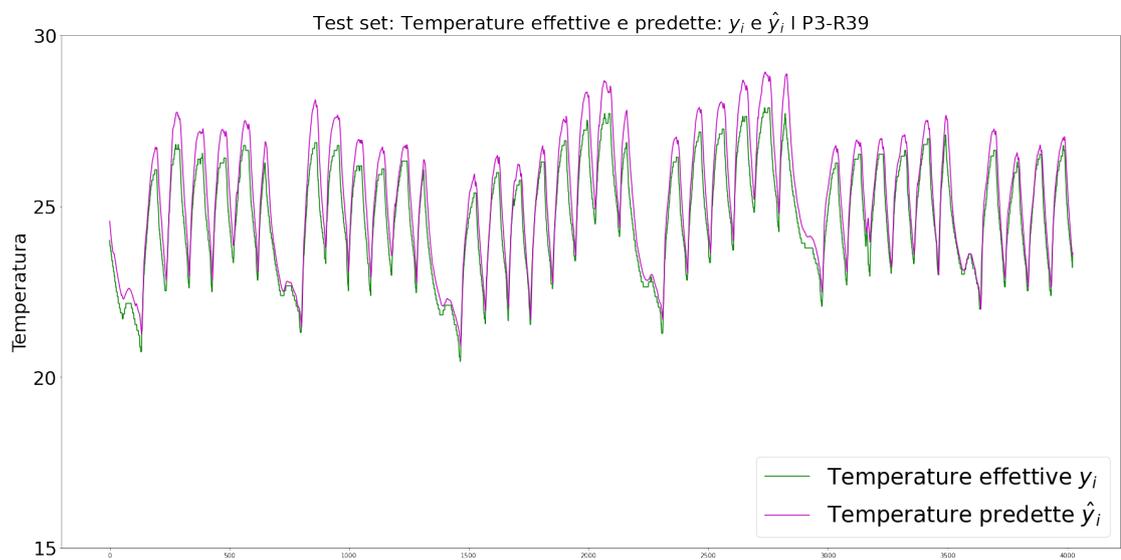


Figura 4.84: Temperature effettive e predette - orizzonte di predizione di 2 ore - test set P3R39 - Approccio MIMO

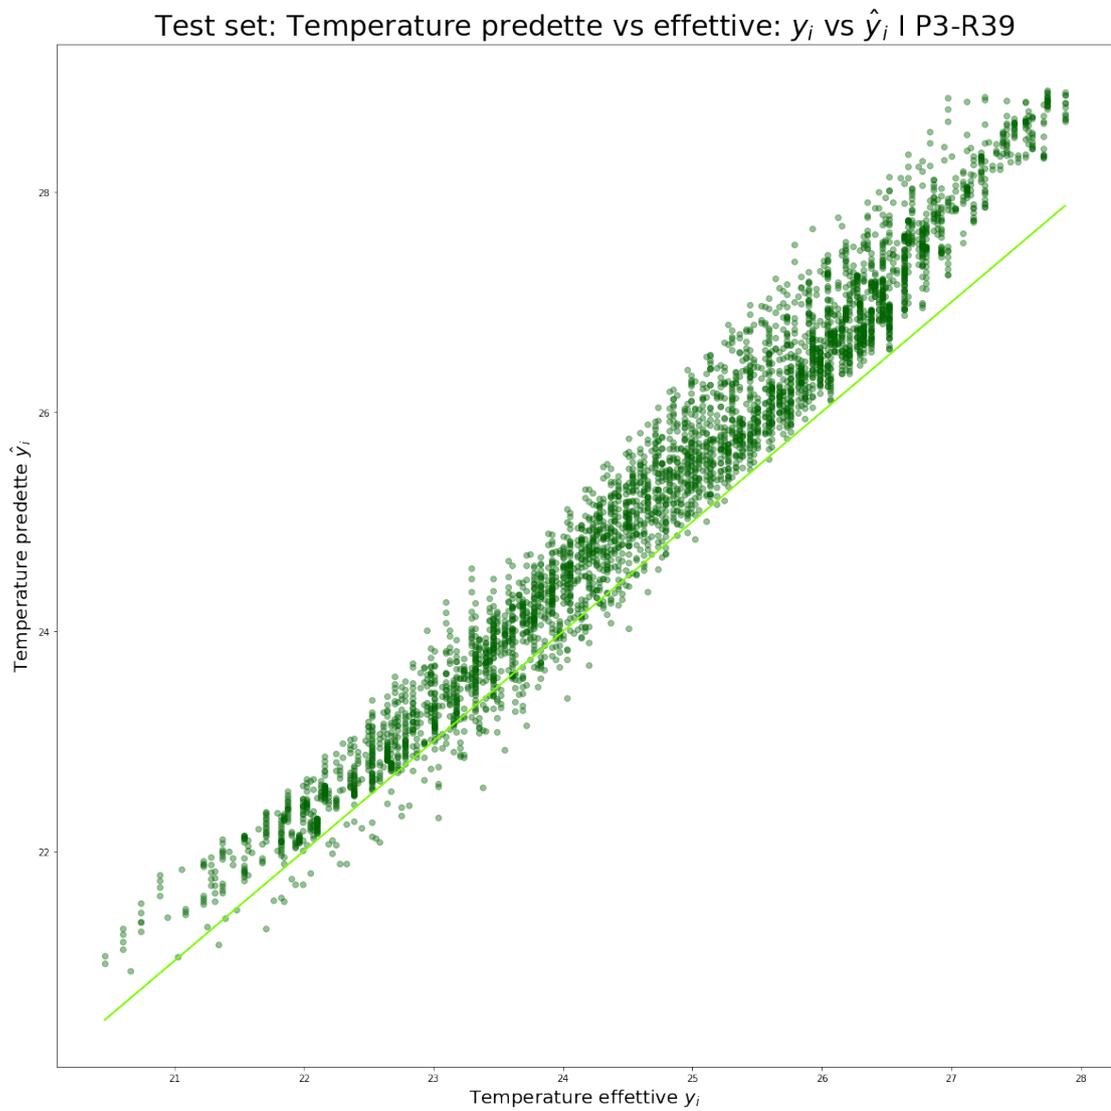


Figura 4.85: Temperature effettive vs predette - orizzonte di predizione di 2 ore - test set P3R39 - Approccio MIMO

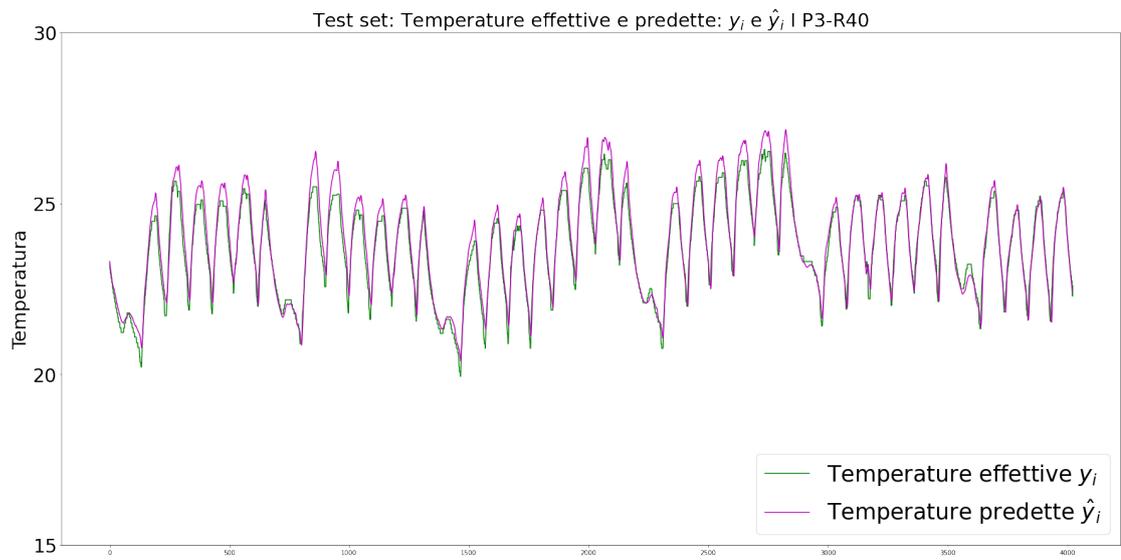


Figura 4.86: Temperature effettive e predette - orizzonte di predizione di 2 ore - test set P3R40 - Approccio MIMO

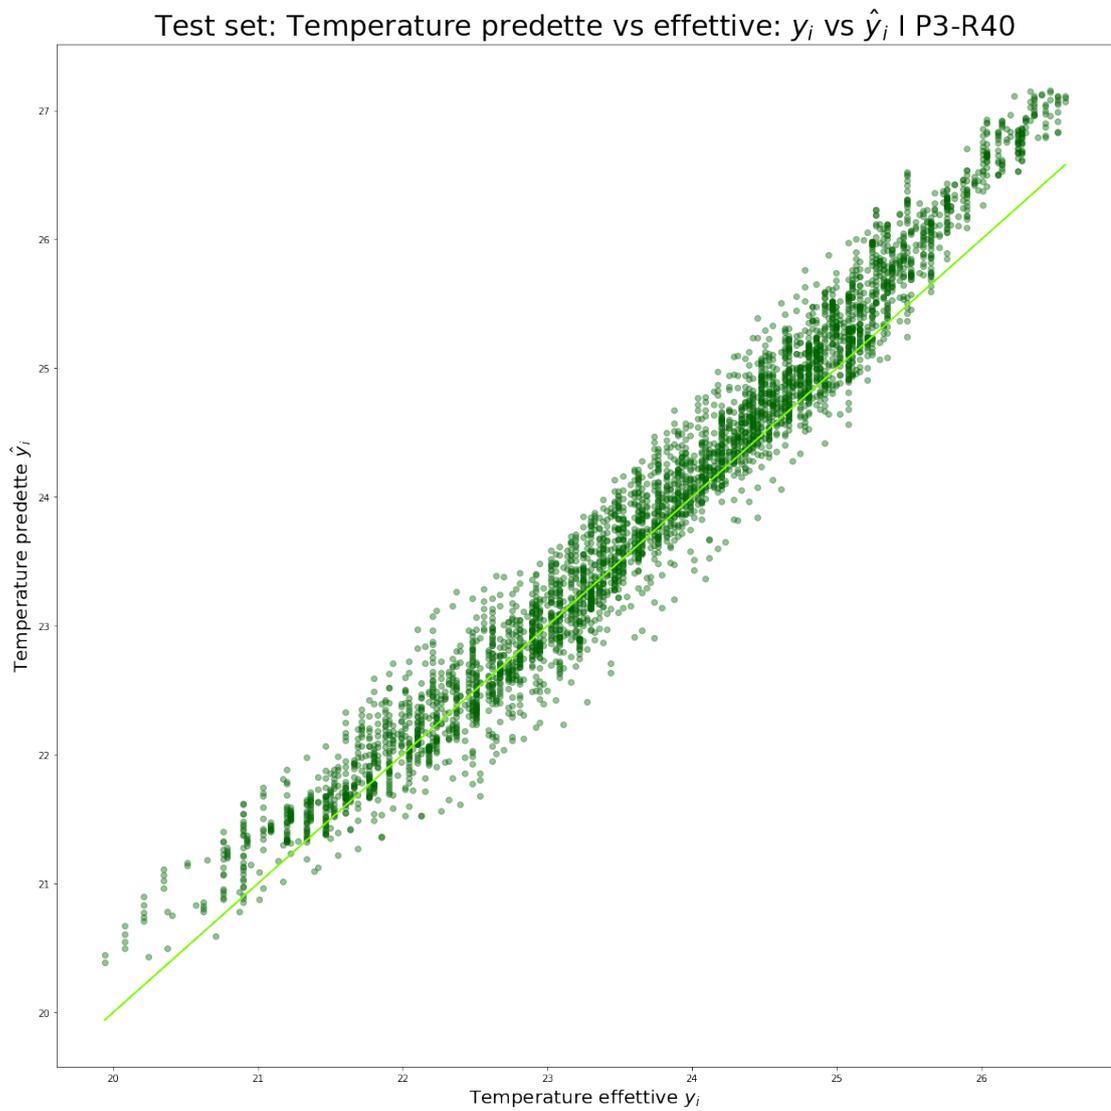


Figura 4.87: Temperature effettive vs predette - orizzonte di predizione di 2 ore - test set P3R40 - Approccio MIMO

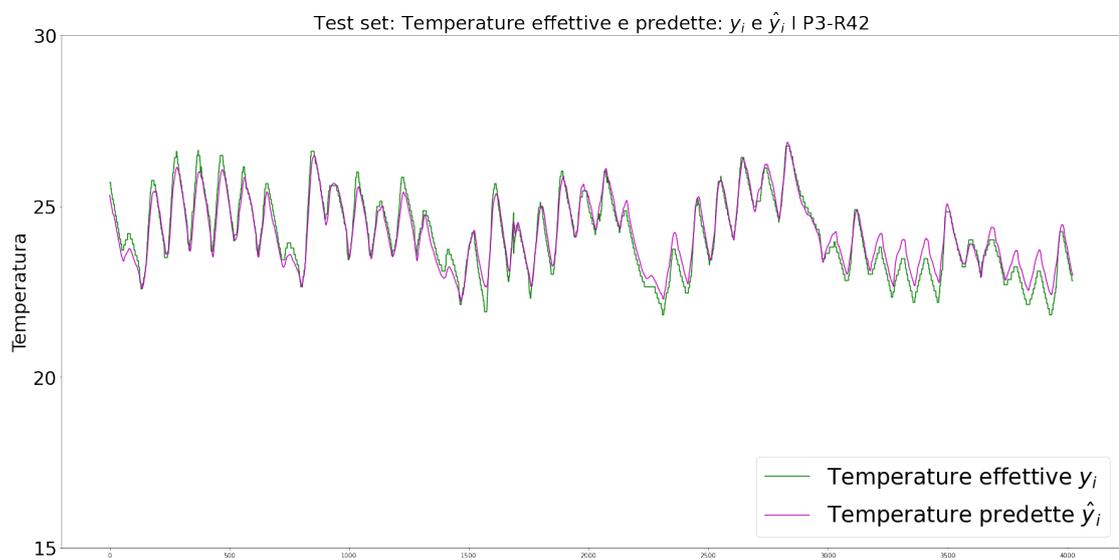


Figura 4.88: Temperature effettive e predette - orizzonte di predizione di 2 ore - test set P3R42 - Approccio MIMO

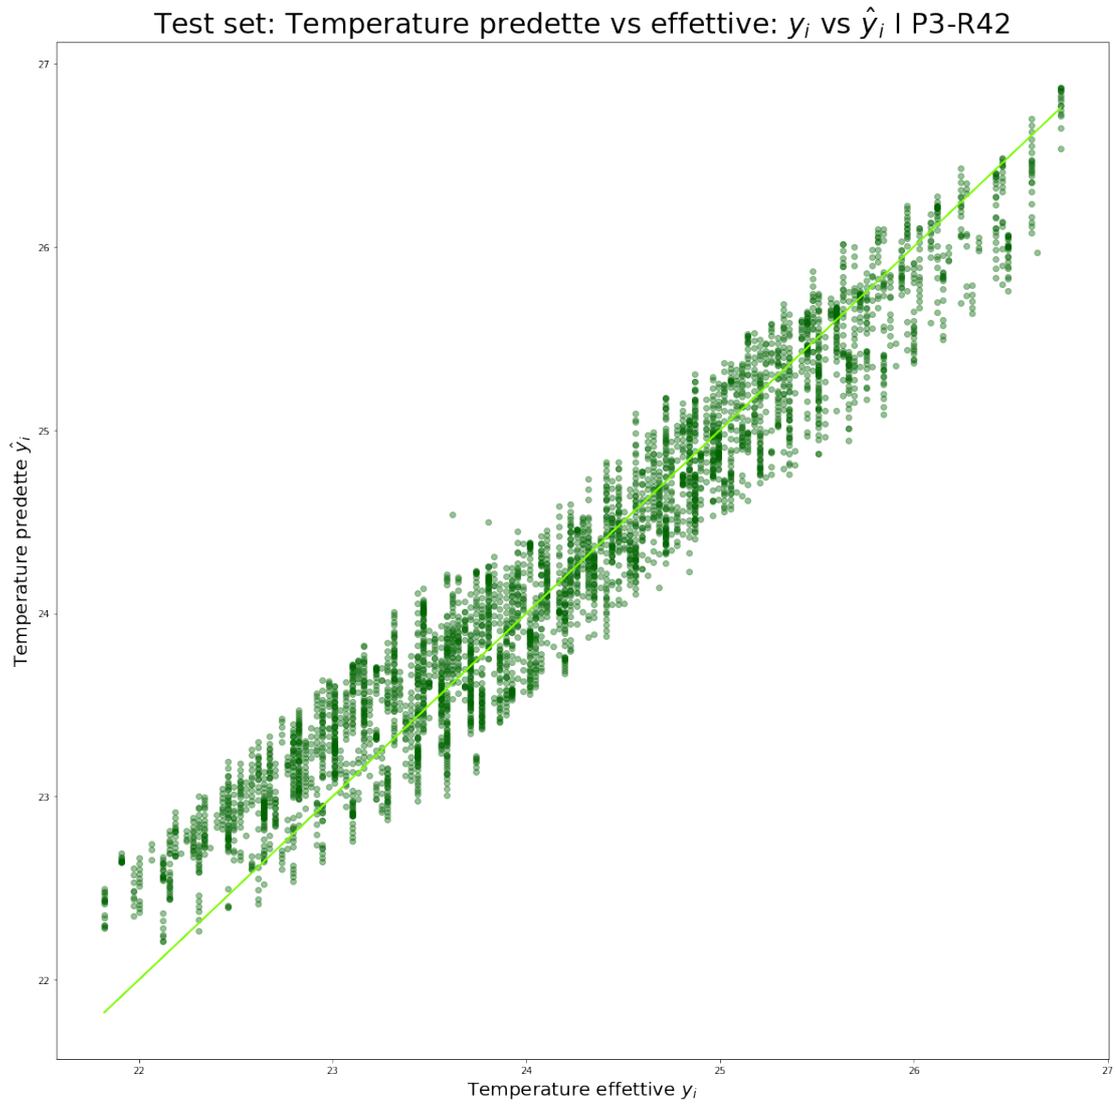


Figura 4.89: Temperature effettive vs predette - orizzonte di predizione di 2 ore - test set P3R42 - Approccio MIMO

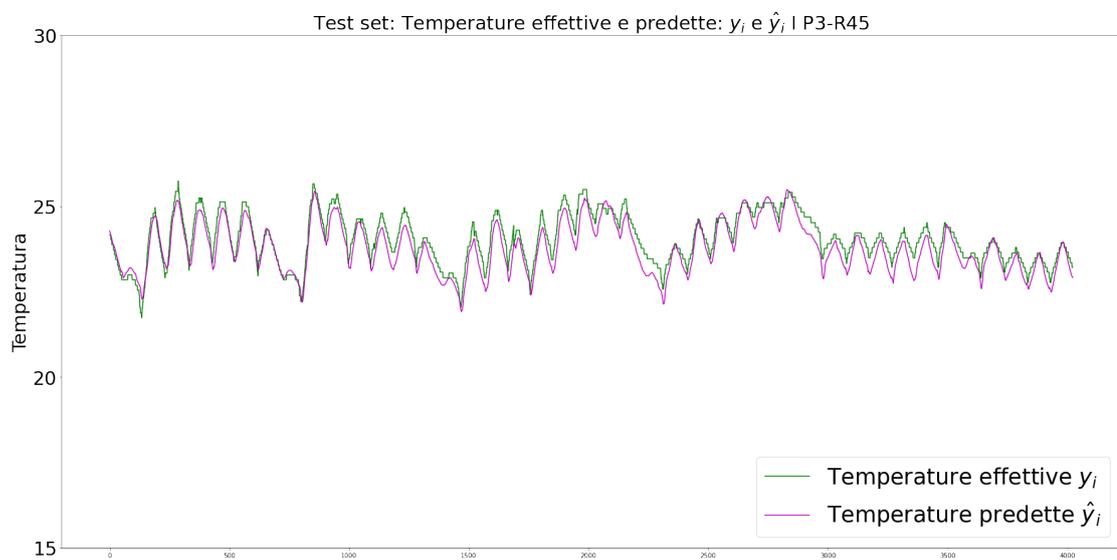


Figura 4.90: Temperature effettive e predette - orizzonte di predizione di 2 ore - test set P3R45 - Approccio MIMO

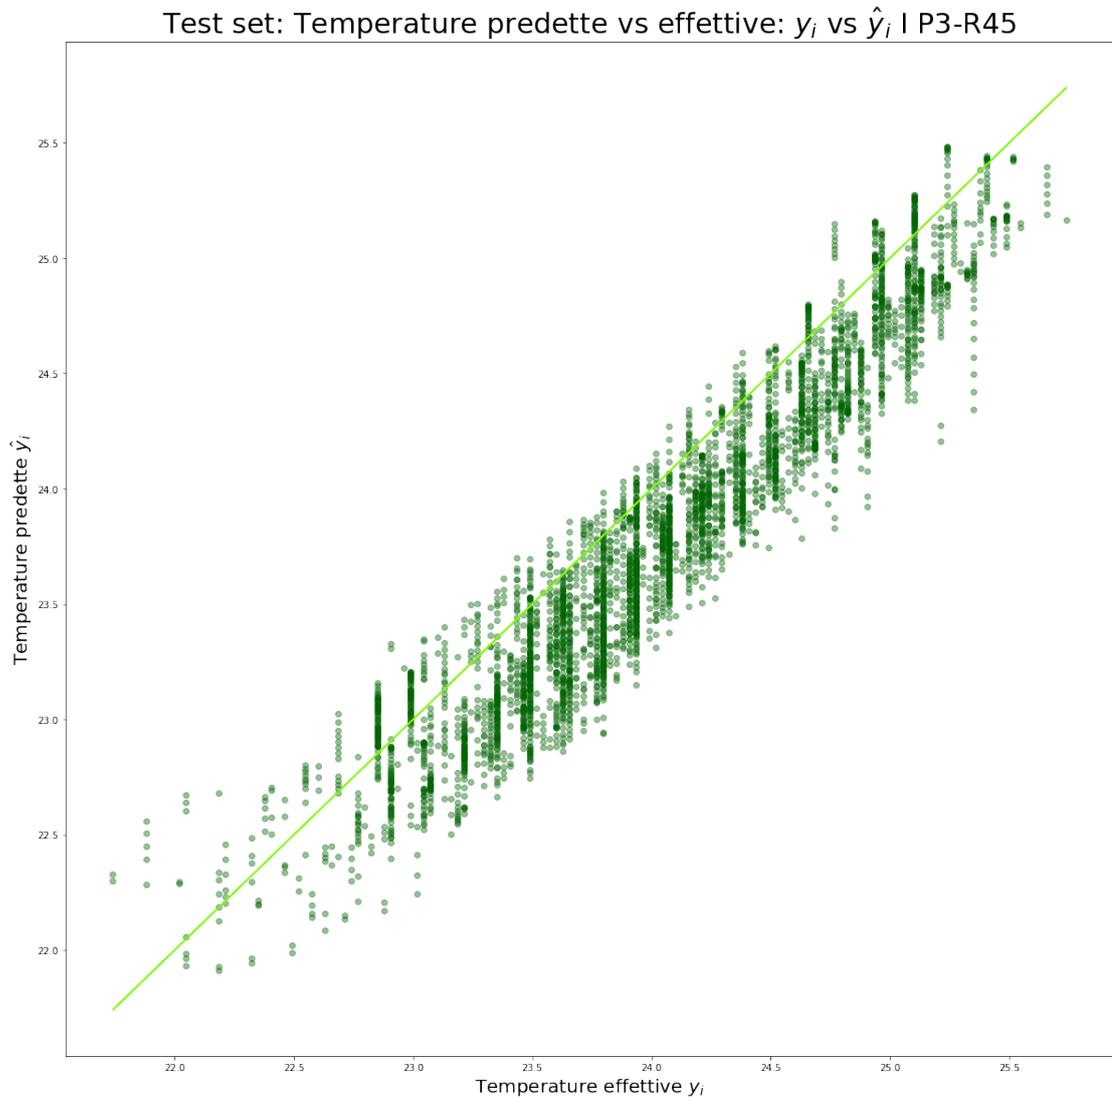


Figura 4.91: Temperature effettive vs predette - orizzonte di predizione di 2 ore - test set P3R45 - Approccio MIMO

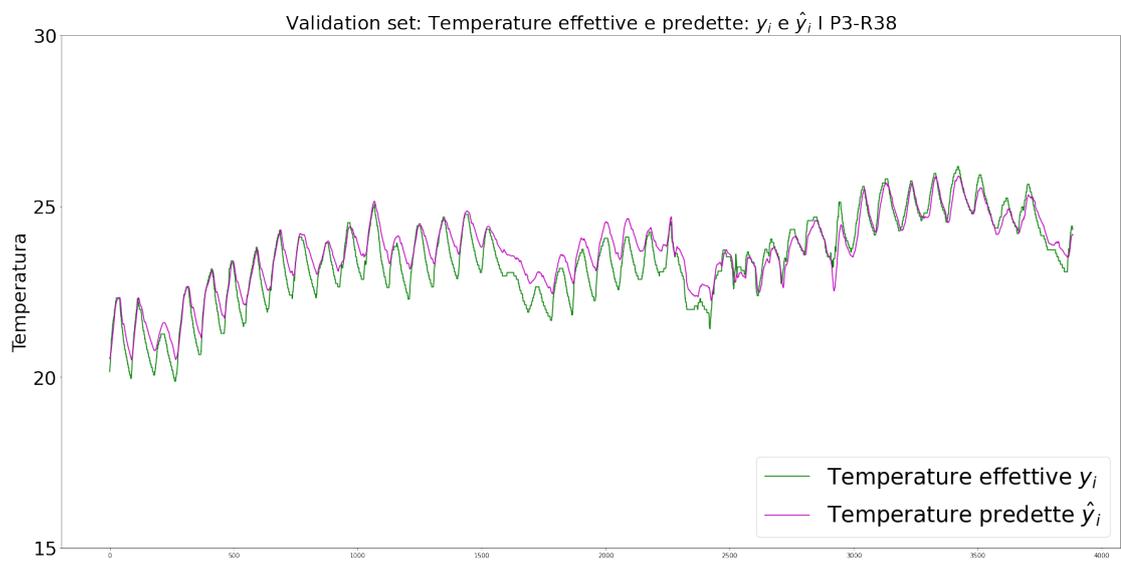


Figura 4.92: Temperature effettive e predette - orizzonte di predizione di 2 ore - validation set P3R38 - Approccio MIMO

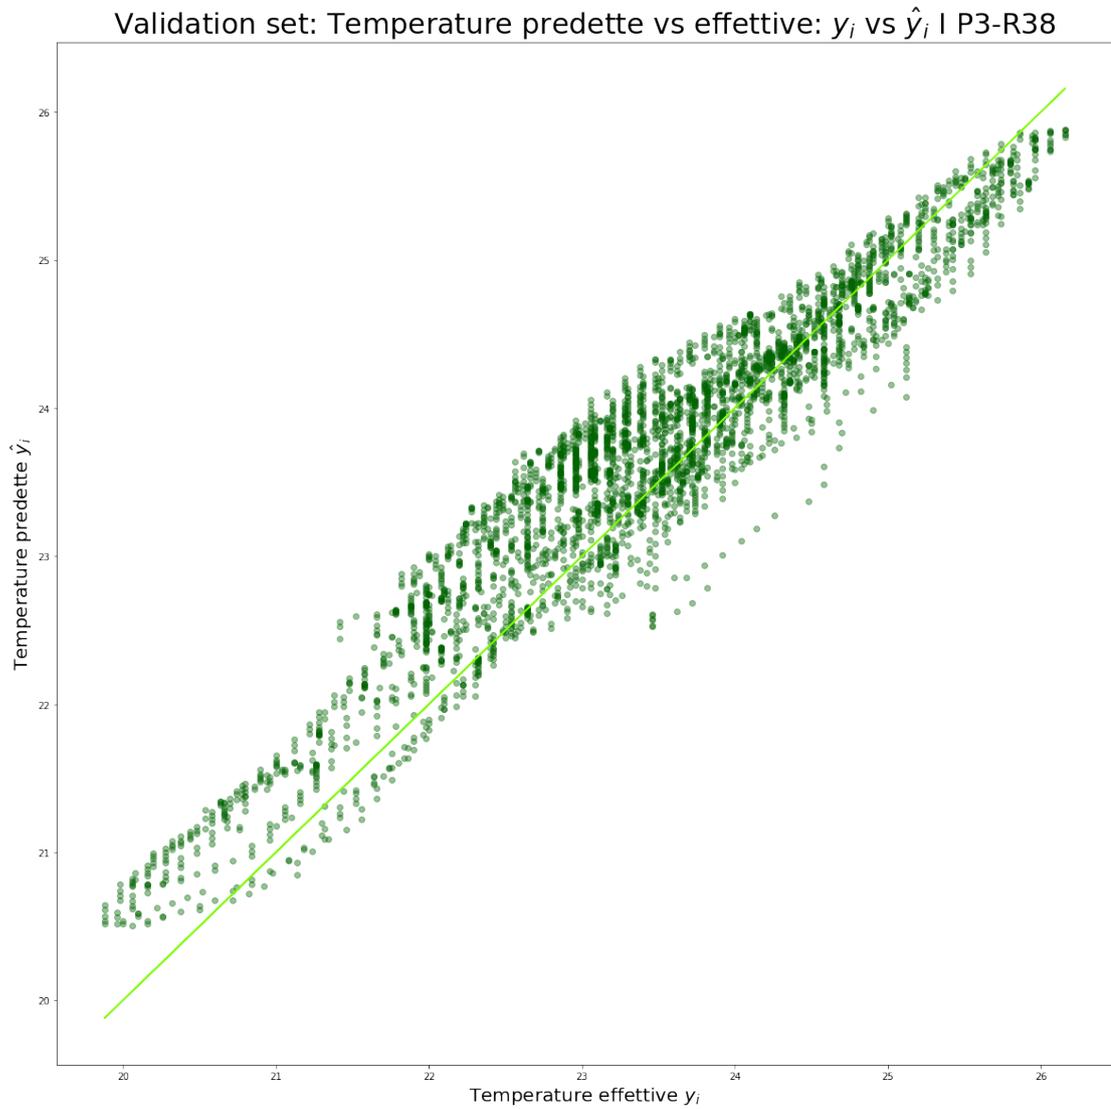


Figura 4.93: Temperature effettive vs predette - orizzonte di predizione di 2 ore - validation set P3R38 - Approccio MIMO

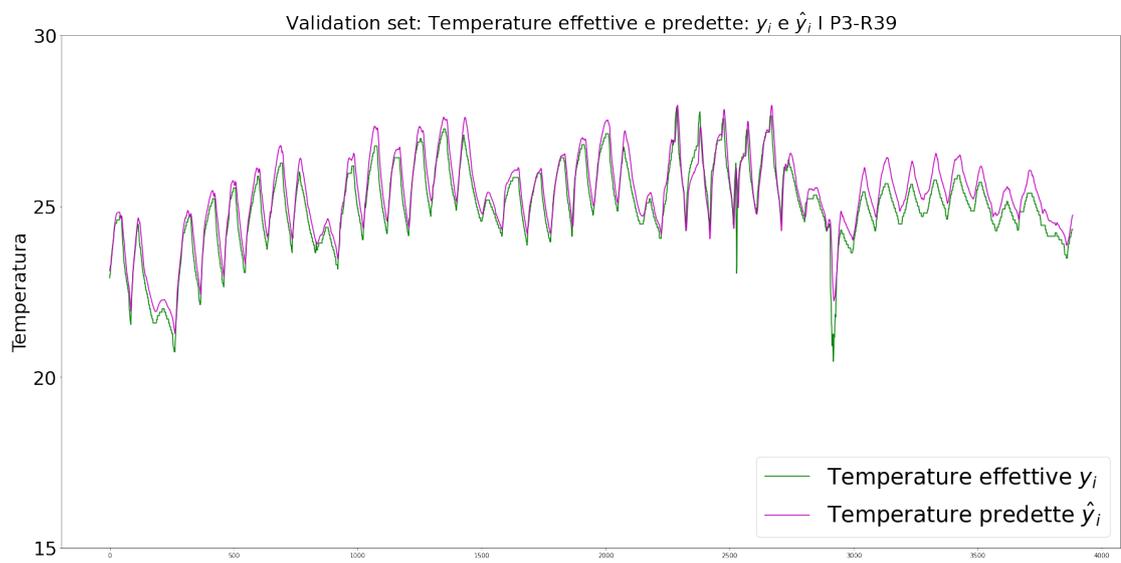


Figura 4.94: Temperature effettive e predette - orizzonte di predizione di 2 ore - validation set P3R39 - Approccio MIMO

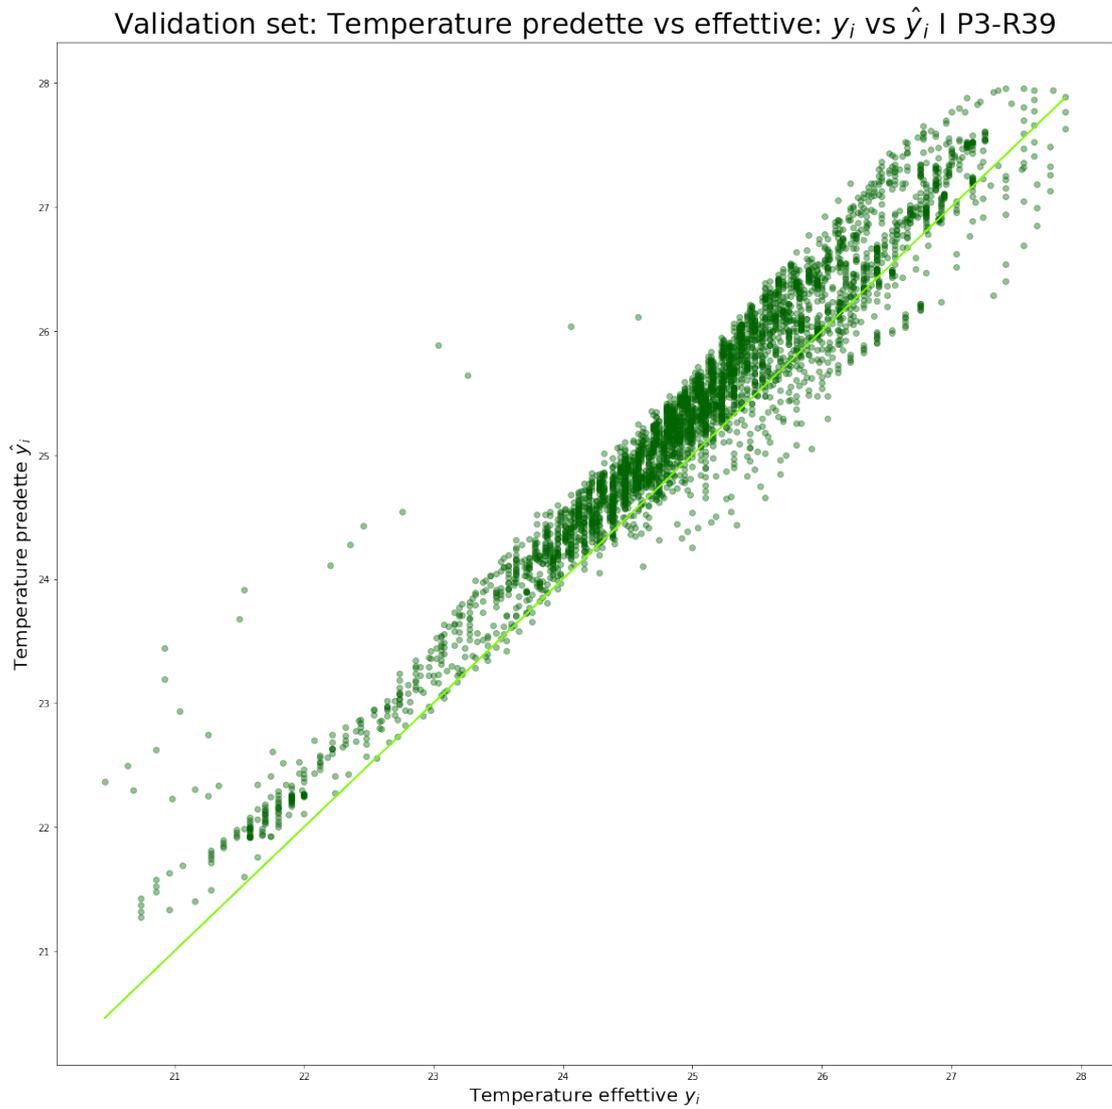


Figura 4.95: Temperature effettive vs predette - orizzonte di predizione di 2 ore - validation set P3R39 - Approccio MIMO

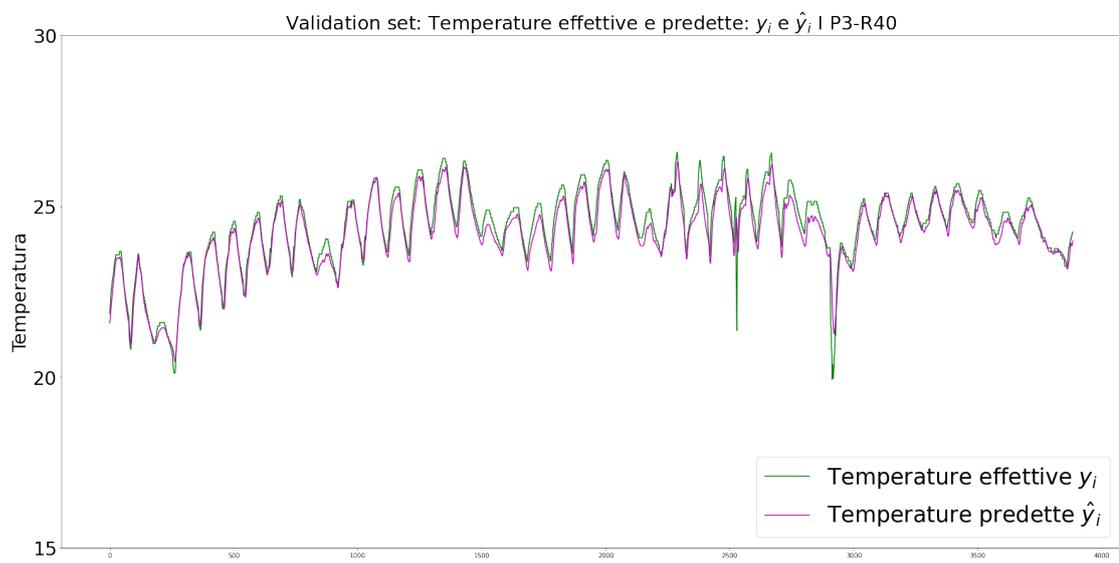


Figura 4.96: Temperature effettive e predette - orizzonte di predizione di 2 ore - validation set P3R40 - Approccio MIMO

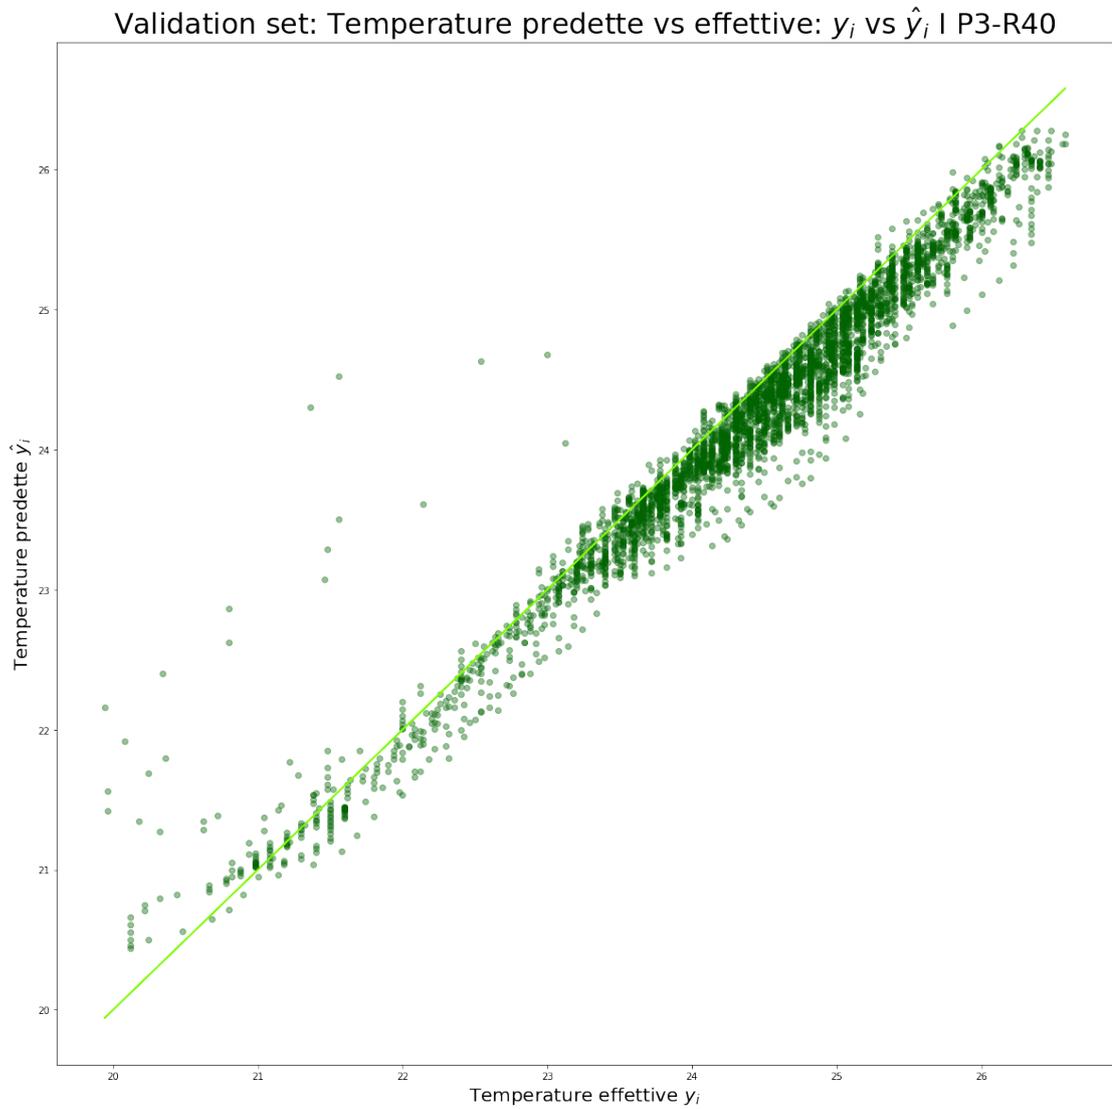


Figura 4.97: Temperature effettive vs predette - orizzonte di predizione di 2 ore - validation set P3R40 - Approccio MIMO

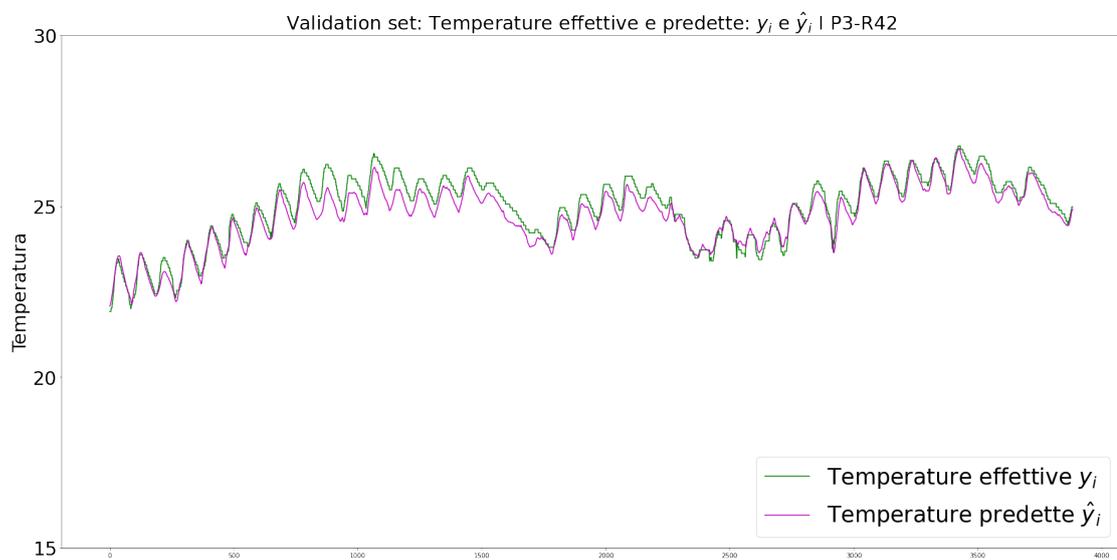


Figura 4.98: Temperature effettive e predette - orizzonte di predizione di 2 ore - validation set P3R42 - Approccio MIMO

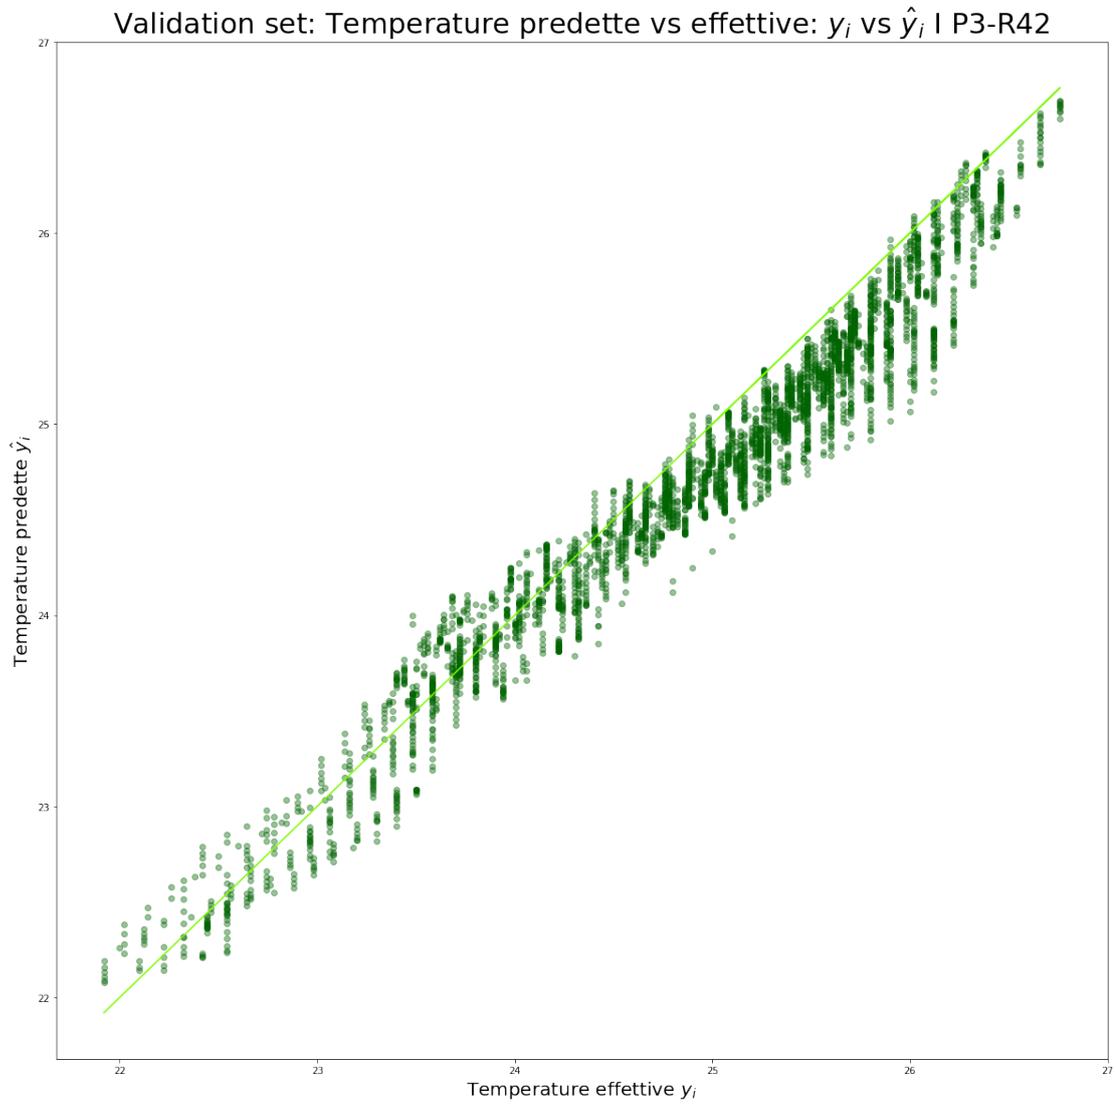


Figura 4.99: Temperature effettive vs predette - orizzonte di predizione di 2 ore - validation set P3R42 - Approccio MIMO

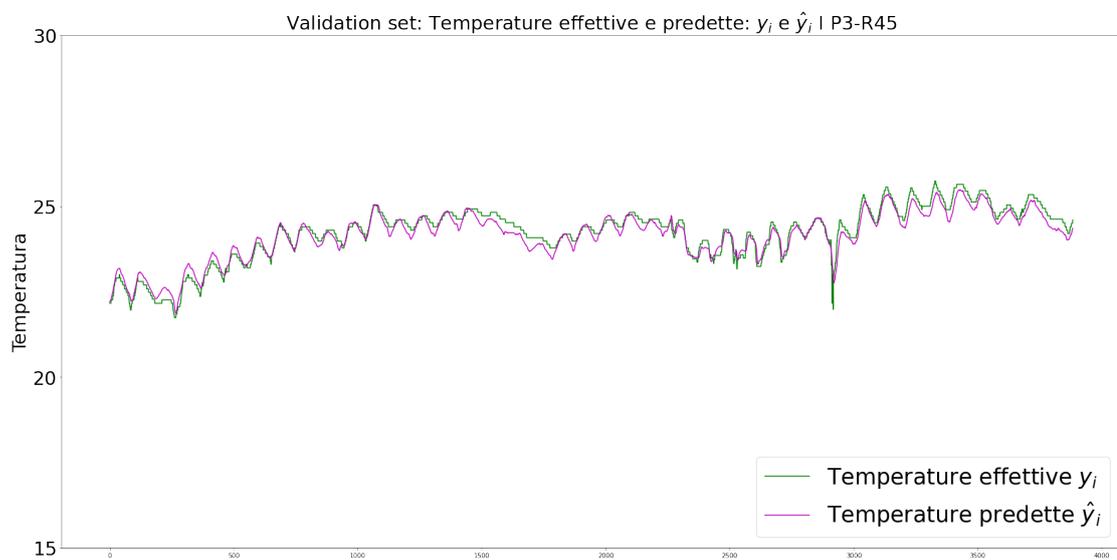


Figura 4.100: Temperature effettive e predette - orizzonte di predizione di 2 ore - validation set P3R45 - Approccio MIMO

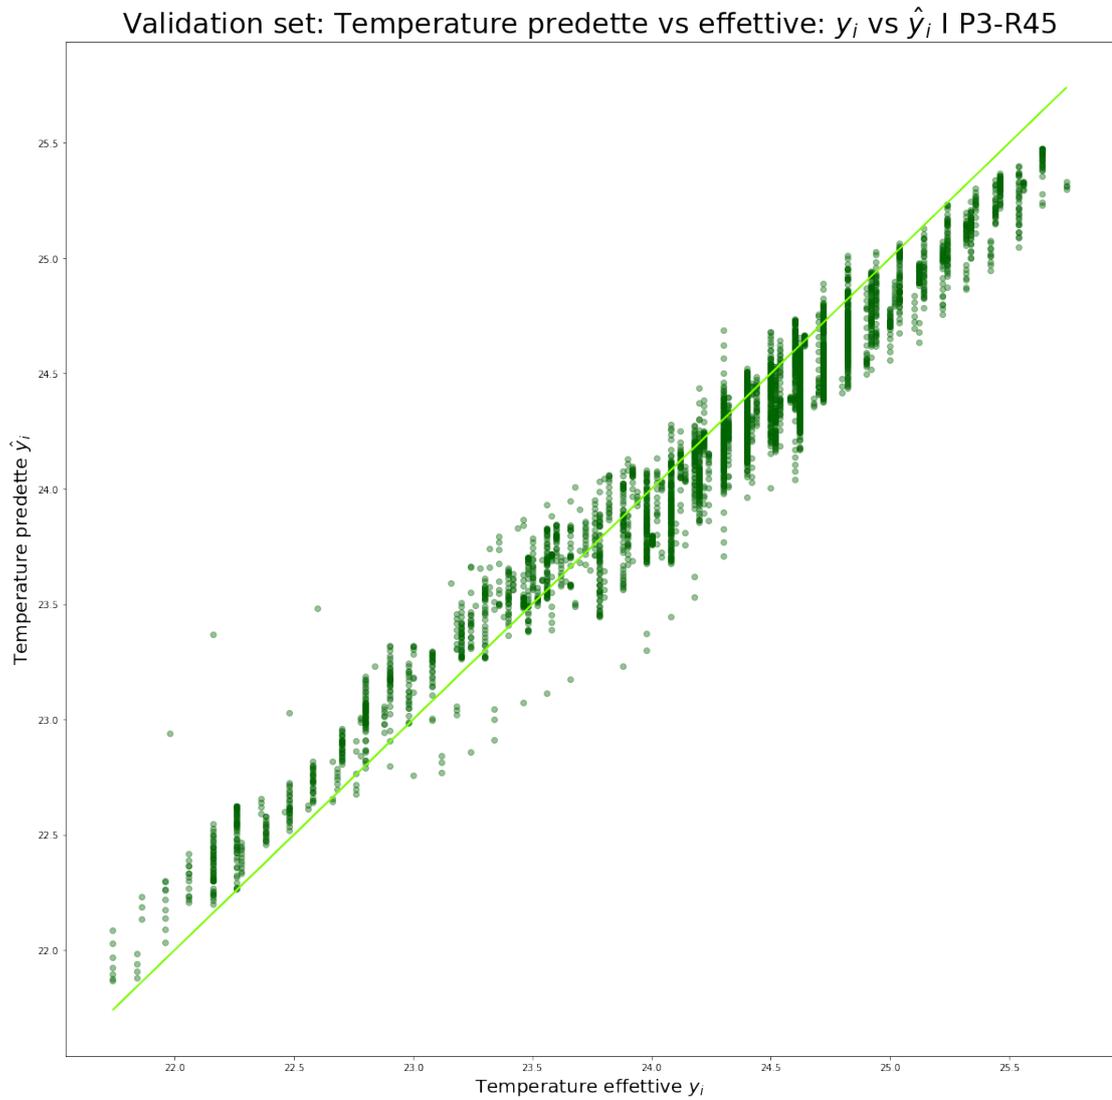


Figura 4.101: Temperature effettive vs predette - orizzonte di predizione di 2 ore - validation set P3R45 - Approccio MIMO

In conclusione, le tabelle 4.4-4.9 riportano tutti gli errori ottenuti attraverso l'approccio MIMO, sia utilizzando l'indicatore RMSE che MAE.

Tabella 4.4: Tabella riepilogativa dei risultati ottenuti - RMSE - Primo Piano - Approccio MIMO

RMSE										
Primo piano										
	Test set					Validation set				
	P1-R40	P1-R38	P1-R39	P1-R42	P1-R45	P1-R40	P1-R38	P1-R39	P1-R42	P1-R45
2 ore	0,0637	0,0474	0,0752	0,0447	0,0755	0,0628	0,0579	0,0516	0,0339	0,0625
5 ore	0,0635	0,0589	0,0692	0,0527	0,0757	0,0404	0,0515	0,0394	0,0391	0,0642
24 ore	0,0575	0,0499	0,0801	0,0687	0,0743	0,063	0,0553	0,0507	0,045	0,0608

Tabella 4.5: Tabella riepilogativa dei risultati ottenuti - MAE - Primo Piano - Approccio MIMO

MAE										
Primo piano										
	Test set					Validation set				
	P1-R40	P1-R38	P1-R39	P1-R42	P1-R45	P1-R40	P1-R38	P1-R39	P1-R42	P1-R45
2 ore	0,0518	0,0366	0,0532	0,0349	0,056	0,0535	0,0434	0,0451	0,0264	0,0499
5 ore	0,0521	0,0473	0,0475	0,0396	0,0584	0,0325	0,0412	0,0329	0,03	0,0526
24 ore	0,047	0,0393	0,0621	0,0497	0,0569	0,0531	0,0427	0,0447	0,0312	0,0492

Tabella 4.6: Tabella riepilogativa dei risultati ottenuti - RMSE - Secondo Piano - Approccio MIMO

RMSE										
Secondo piano										
	Test set					Validation set				
	P1-R40	P1-R38	P1-R39	P1-R42	P1-R45	P1-R40	P1-R38	P1-R39	P1-R42	P1-R45
2 ore	0,0705	0,0588	0,1007	0,0498	0,0529	0,097	0,0396	0,062	0,0739	0,0663
5 ore	0,0825	0,0659	0,1132	0,0619	0,0582	0,0971	0,0544	0,0669	0,0933	0,077
24 ore	0,1052	0,0663	0,0941	0,0648	0,0628	0,0906	0,0502	0,0707	0,063	0,0969

Tabella 4.7: Tabella riepilogativa dei risultati ottenuti - MAE - Secondo Piano - Approccio MIMO

MAE										
Secondo piano										
	Test set					Validation set				
	P1-R40	P1-R38	P1-R39	P1-R42	P1-R45	P1-R40	P1-R38	P1-R39	P1-R42	P1-R45
2 ore	0,0539	0,0441	0,0873	0,0387	0,0412	0,0878	0,0311	0,0515	0,0581	0,0542
5 ore	0,0641	0,0455	0,0932	0,0488	0,0436	0,0857	0,0418	0,0541	0,0725	0,061
24 ore	0,0862	0,0444	0,0805	0,0508	0,0504	0,0797	0,0423	0,0607	0,0523	0,0766

Tabella 4.8: Tabella riepilogativa dei risultati ottenuti - RMSE - Terzo Piano - Approccio MIMO

RMSE										
Terzo piano										
	Test set					Validation set				
	P1-R40	P1-R38	P1-R39	P1-R42	P1-R45	P1-R40	P1-R38	P1-R39	P1-R42	P1-R45
2 ore	0,0501	0,0798	0,0867	0,0606	0,086	0,0458	0,0703	0,0562	0,0616	0,0486
5 ore	0,0458	0,0705	0,0908	0,0648	0,0975	0,054	0,0619	0,0661	0,0581	0,0539
24 ore	0,0615	0,0639	0,0945	0,0783	0,0766	0,056	0,0763	0,0777	0,0661	0,0488

Tabella 4.9: Tabella riepilogativa dei risultati ottenuti - MAE - Terzo Piano - Approccio MIMO

MAE										
Terzo piano										
	Test set					Validation set				
	P1- R40	P1- R38	P1- R39	P1- R42	P1- R45	P1- R40	P1- R38	P1- R39	P1- R42	P1- R45
2 ore	0,0396	0,0673	0,0744	0,0498	0,0735	0,0344	0,0563	0,0472	0,0512	0,0405
5 ore	0,0369	0,0567	0,0791	0,0522	0,0826	0,0406	0,0512	0,0547	0,0472	0,0417
24 ore	0,0463	0,0509	0,0791	0,064	0,0632	0,0393	0,0617	0,0654	0,0551	0,0389

Capitolo 5

Lavori futuri

Nell'ottica di un successivo approfondimento del caso studio, sarebbe auspicabile effettuare predizioni relative alla temperatura indoor nei diversi uffici su una scala più estesa, sfruttando in questo modo appieno le potenzialità dei modelli predittivi proposti, oppure ricorrendo a modelli in grado di oltrepassare il limite dei tempi e costi computazionali proibitivi. La possibilità di predire con un visione in anticipo di diversi giorni è di indiscussa utilità al fine di ottimizzare i consumi, far fronte ad eventuali malfunzionamenti e gestire la domanda energetica. D'altro canto, si tratta di un tema già ampiamente esplorato in letteratura, dove si sono ottenuti risultati notevoli, giungendo ad effettuare predizioni su variabili anche in anticipo di mesi.

Un ulteriore approfondimento consisterebbe nella naturale prosecuzione del task di predizione, ovvero l'instaurazione di una metodologia di controllo della variabile controllata, che potrebbe essere identificata nella temperatura di mandata dei collettori dei pannelli radianti, sulla base delle predizioni osservate per le variabili osservate, dunque le temperature ambiente dei vari uffici, e delle variabili di riferimento, ovvero le temperature di set point dei vari uffici. Questa metodologia trova ampiamente applicazione all'interno di sistemi dinamici complessi, ed è in grado di minimizzare una specifica funzione di costo servendosi di un algoritmo di ottimizzazione.

Capitolo 6

Conclusioni

Questo studio ha permesso di mettere alla prova su un vasto dataset di rilevazioni effettuate tra l'estate 2019 e l'estate 2020 all'interno di un edificio reale di tre piani, presente a Torino, in Piemonte, uno dei modelli più utilizzati in letteratura con finalità di predizione, una rete neurale artificiale LSTM. L'obiettivo di identificare le temperature ambiente all'interno di ogni ufficio appartenente alla sezione dell'edificio presa in considerazione è stato perseguito considerando due scenari: lo scenario MISO, in grado di restituire la sola variabile riferita all'ufficio R-40 presente su tutti e tre i piani, e lo scenario MIMO, che produce in risposta una stima delle temperature di tutti i cinque uffici presenti su ciascun piano. L'architettura e i parametri della rete neurale sono stati identificati sulla base di un vasto numero di simulazioni, che hanno permesso di individuare le caratteristiche più adeguate sia per una predizione più a breve termine, nell'arco delle successive 2 e 5 ore, sia per una predizione più a lungo termine, estesa fino a un giorno in avanti. La struttura individuata per tutte le casistiche possiede un solo hidden layer, in quanto è stato spesso dimostrato in letteratura che un modello di rete neurale artificiale accurato non necessariamente deve essere particolarmente esteso, anzi: i migliori modelli spesso non sono composti da più di quattro strati. I test hanno messo in evidenza che:

- Un aumento dell'ampiezza dell'orizzonte temporale causa un deterioramento delle performance del modello; se, dunque, la possibilità di predire in anticipo per un intero giorno si rivelerebbe estremamente preziosa in casi come, per esempio, un guasto prolungato dei sensori adibiti al monitoraggio, queste predizioni risentono comunque di un errore più pronunciato.
- Lo scenario MISO, rispetto all'approccio MIMO, caratterizzato da una maggiore complessità, consente sistematicamente una migliore precisione, pur restituendo un risultato più incompleto.

- Lo scostamento tra i valori effettivi e quelli predetti risulta più significativo nel caso del secondo e del terzo piano: si deve tenere conto, infatti, che ciascun piano presenta una diversa complessità, perché caratterizzato da dinamiche differenti. Il terzo piano, contrariamente agli altri due, presenta la peculiarità della copertura, mentre il secondo si trova in una posizione tale da subire anche l'influenza dei due piani adiacenti, non tenuta in conto dalle variabili in input.
- La struttura bidirezionale permette di ottenere ottimi risultati, ma le sue prestazioni calano con l'allungamento dell'orizzonte di predizione, tanto che per l'orizzonte di tempo più esteso è necessario ricorrere nuovamente alla struttura tradizionale, meno sensibile a questa problematica.
- Il learning rate scelto nell'ottica di ottenere la massima stabilità possibile dell'errore con il trascorrere delle epoche d'allenamento è molto basso (0.000001), ma, dal momento che l'ottimizzatore che risulta sistematicamente superiore è Adam, quello caratterizzato dalla massima velocità di convergenza, i tempi computazionali non risultano mai particolarmente proibitivi.
- La numerosità più alta testata (256 neuroni) è quella che garantisce le migliori prestazioni, dal momento che il rischio di overfitting è limitato dalla presenza di uno specifico modello per ciascun piano.

La validità della soluzione identificata trova una conferma nel confronto con altri modelli presenti in letteratura. Effettuando una rapida comparazione con altri risultati ottenuti su edifici simili (virtuali o reali), evitando le casistiche che prendono in considerazione climatiche estreme o modelli di regressione che si discostano da quello scelto per il presente studio, risulta evidente che il margine d'errore ottenuto è perfettamente in linea con quelli registrati in altri studi. La tabella 5.1 riporta una rapida overview dei risultati dello studio presente a confronto di lavori precedenti, tenendo conto che una comparazione precisa è resa impossibile dalla diversa complessità degli edifici target, dalla minore numerosità degli altri modelli (che mediamente contano una ventina di neuroni per layer) dovuta alla necessità di funzionare sull'intero edificio, e da una disponibilità a volte inferiore di dati da destinare al training. In conclusione, gli errori registrati si possono ritenere pienamente accettabili in quanto lo scostamento dei valori predetti rispetto a quelli effettivi si mantiene mediamente sempre al di sotto del $0,1^{\circ}\text{C}$, sufficiente per poter affermare che una gestione ottimizzata dei parametri controllati sulla base di tali predizioni consentirebbe un risparmio di energia significativo.

Tabella 6.1: Tabella di confronto dei risultati con alcuni riferimenti - Approccio MIMO [33] . Tutti i risultati mostrati sono frutto di approssimazioni

Studi	Ampiezza dell'orizzonte di predizione	RMSE
Presente	2 ore - 1 giorno	0,06308 - 0,069
Mustafaraj et al. (2011) [23]	30 minuti - 3 ore	0,127 - 0,4273
Lu et Viljanen (2009) [51]	15 minuti - 1 ora	0,177 - 0,23
Mustafaraj et al. (2010) [52]	30 minuti - 2 ore	0,1326 - 0,4182
Chernbumroong et al. (2014) [53]	1 giorno - 7 giorni	0,1259 - 0,1895 (dataset1); 0,13 - 0,2211 (dataset2)
Afroz et al. (2018) [33]	5 minuti - 28 giorni	0,0547 - 0,288

Bibliografia

- [1] PARLAMENTO EUROPEO, 19 Maggio 2010. *DIRETTIVA 2010/31/UE DEL PARLAMENTO EUROPEO E DEL CONSIGLIO del 19 maggio 2010 sulla prestazione energetica nell'edilizia*. (cit a pg. 5,6).
- [2] European Commission *Eurostat*, 2018 (cit a pg. 3,4).
- [3] International Energy Agency, UN Environment Programme *Global Alliance for Buildings and Construction, International Energy Agency and the United Nations Environment Programme (2019): 2019 global status report for buildings and construction: Towards a zero-emission, efficient and resilient buildings and construction sector*, 2019 (cit a pg. 2).
- [4] Arkadiusz Węglarz *Using Artificial Intelligence in energy efficient construction*, E3S Web of Conferences 49, 00125 (2018), URL <https://doi.org/10.1051/e3sconf/20184900125>, EDP Sciences (cit a pg. 7,8,9).
- [5] Department of Energy United States of America *An assessment of energy technologies and research opportunities - Chapter 5: Increasing Efficiency of Building Systems and Technologies*, settembre 2015, (cit pg. 5,6,7,8,9,10).
- [6] B. Delinchant, H.A. Dang, H.T.T. Vu, D.Q. Nguyen *Massive arrival of low-cost and low-consuming sensors in buildings: towards new building energy services*, 2019 5th International Conference on Environment and Renewable Energy, IOP Publishing doi:0.1088/1755-1315/307/1/012006, IOP Conf. Series: Earth and Environmental Science 307 (2019) 012006, (cit pg. 9, 10).
- [7] Richard Evans, Jim Gao *DeepMind AI Reduces Google Data Centre Cooling Bill by 40%*, URL: <https://deepmind.com/blog/article/deepmind-ai-reduces-google-data-centre-cooling-bill-40> , 20 Luglio 2016 (cit pg. 13, 14).
- [8] Joana Sousa *Energy Simulation Software for Buildings: Review and Comparison*, CiteSeerX, URL: <http://citeseerx.ist.psu.edu/viewdoc/summary?doi=10.1.1.416.7812> , (cit pg. 15, 16, 17, 18, 19, 20, 21, 23, 24, 25, 26).
- [9] ASHRAE *ASHRAE Handbook - Fundamentals*, Atlanta: American Society of Heating, Refrigerating and Air-Conditioning Engineers, Inc., 2001, (cit pg. 26).

- [10] Fatima Amara, Kodjo Agbossou, Alben Cardenas, Yves Dubé, Souso Kelou-wani *Comparison and Simulation of Building Thermal Models for Effective Energy Management*, Smart Grid and Renewable Energy Vol.06 No.04(2015), Article ID:56069,17 pages 10.4236/sgre.2015.64009 , 30 Aprile 2015, (cit a pg. 23, 24, 25, 26, 27, 28, 32, 33).
- [11] Jacopo Vivian, Angelo Zarrella, Giuseppe Emmi, Michele De Carli *An evaluation of the suitability of lumped-capacitance models in calculating energy needs and thermal behaviour of buildings*, Energy and Buildings Volume 150, 1 September 2017, Pages 447-465 URL: <https://doi.org/10.1016/j.enbuild.2017.06.021> , (cit a pg. 34, 35, 36, 37).
- [12] Gilles Fraisse, Christelle Viardot, Olivier Lafabrie, Gilbert Achard *Development of a simplified and accurate building model based on electrical analogy*, Energy and Buildings Volume 34, Issue 10, November 2002, Pages 1017-1031, URL [https://doi.org/10.1016/S0378-7788\(02\)00019-1](https://doi.org/10.1016/S0378-7788(02)00019-1) , (cit a pg. 37, 38, 39).
- [13] Alfonso P. Ramallo-González, Matthew E. Eames, David A. Coley *Lumped parameter models for building thermal modelling: An analytic approach to simplifying complex multi-layered constructions*, Energy and Buildings Volume 60, May 2013, Pages 174-184, URL: <https://doi.org/10.1016/j.enbuild.2013.01.014> , (cit a pg. 40, 41).
- [14] Shengwei Wang, Xinhua Xu *Simplified building model for transient thermal performance estimation using GA-based parameter identification*, International Journal of Thermal Sciences Volume 45, Issue 4, April 2006, Pages 419-432, URL: <https://doi.org/10.1016/j.ijthermalsci.2005.06.009> , (cit a pg. 42, 43, 44, 45).
- [15] Annamaria Buonomano *Code-to-Code Validation and Application of a Dynamic Simulation Tool for the Building Energy Performance Analysis*, Energies 2016, 9(4), 301, URL: <https://doi.org/10.3390/en9040301> , (cit a pg. 45, 46, 47).
- [16] James E. Braun, Nitin Chaturvedi (2002) *An Inverse Gray-Box Model for Transient Building Load Prediction*, HVACR Research, 8:1, 73-99, 2011, URL <https://doi.org/10.1080/10789669.2002.10391290> , (cit pg. 47, 48, 49).
- [17] Ricky T. Q. Chen, Yulia Rubanova, Jesse Bettencourt, David Duvenaud *Neural Ordinary Differential Equations*, 32nd Conference on Neural Information Processing Systems (NeurIPS 2018), Montréal, Canada, URL arXiv:1806.07366v5 [cs.LG] , (cit pg. 50, 51, 52).
- [18] Anuj Karpatne, William Watkins, Jordan Read, Vipin Kumar *Physics-guided Neural Networks (PGNN): An Application in Lake Temperature Modeling*, 2018, URL arXiv:1710.11431v2 [cs.LG] (cit pg. 52, 53).
- [19] Marco Massano, Edoardo Patti, Enrico Macii, Andrea Acquaviva, Lorenzo Bottaccioli *An Online Grey-Box Model Based on Unscented Kalman Filter to Predict Temperature Profiles in Smart Buildings* , Energies 2020, 13(8), 2097; URL: <https://doi.org/10.3390/en13082097> , (cit pg. 53, 54).

- [20] Sadi Alawadi, David Mera, Manuel Fernández-Delgado, Fahed Alkhabbas *A comparison of machine learning algorithms for forecasting indoor temperature in smart buildings*, Energy Systems (2020), URL: <https://doi.org/10.1007/s12667-020-00376-x> , (cit pg. 57, 60).
- [21] Zakia Afroz, Gm Shafiullah, Tania Urmee, Gary Higgins *Prediction of Indoor Temperature in an Institutional Building*, 9th International Conference on Applied Energy, ICAE2017, 21-24 August 2017, Cardiff, UK, Published by Elsevier, 2017, URL: [10.1016/j.egypro.2017.12.576](https://doi.org/10.1016/j.egypro.2017.12.576) , (cit pg. 60, 61).
- [22] Bruce Spencer, Feras Al-Obeidat *Temperature Forecasts with Stable Accuracy in a Smart Home*, Procedia Computer Science Volume 83, 2016, Pages 726-733, URL: <https://doi.org/10.1016/j.procs.2016.04.160>, (cit pg. 61).
- [23] G.Mustafaraj, G.Lowry, J.Chen *Prediction of room temperature and relative humidity by autoregressive linear and nonlinear neural network models for an open office*, Energy and Buildings Volume 43, Issue 6, June 2011, Pages 1452-1460 URL: <https://doi.org/10.1016/j.enbuild.2011.02.007> , (cit a pg. 62).
- [24] M. Soleimani-Mohsenia, B. Thomas, Per Fahlénc *Estimation of operative temperature in buildings using artificial neural networks*, Energy and Buildings Volume 38, Issue 6, June 2006, Pages 635-640, URL: <https://doi.org/10.1016/j.enbuild.2005.10.004> , (cit pg. 62).
- [25] Hao Huang, Lei Chen, Eric Hu *A neural network-based multi-zone modelling approach for predictive control system design in commercial buildings*, Energy and Buildings Volume 97, 15 June 2015, Pages 86-97, URL: <https://doi.org/10.1016/j.enbuild.2015.03.045> , (cit pg. 63).
- [26] Fernando Mateo Juan, José Carrasco , Abderrahim Sellami , Mónica Millán-Giraldo, Manuel Domínguez , Emilio Soria-Olivas *Machine learning methods to forecast temperature in buildings*, Expert Systems with Applications Volume 40, Issue 4, March 2013, Pages 1061-1068, URL: <https://doi.org/10.1016/j.eswa.2012.08.030> , (cit pg. 59).
- [27] Burak Saltuk, Nazire Mikail *Prediction of indoor temperature in a greenhouse: siirt sample*, Volume 28 – No. 4A/2019 pages 3577-3585 Fresenius Environmental Bulletin, (cit pg. 63).
- [28] Hermawan, Eddy Prianto, Erni Setyowati *Indoor temperature prediction of the houses with exposed stones in tropical mountain regions during four periods of different seasons*, International Journal of Civil Engineering and Technology (IJCIET) Volume 10, Issue 05, May 2019, pp. 604-612 , URL: <http://www.iaeme.com/ijmet/issues.asp?JType=IJCIET&VType=10&IType=5> ISSN Print: 0976-6308 and ISSN Online: 0976-6316 , IAEME Publication, (cit pg. 64).
- [29] Nédra Mellouli, Mahdjouba Akerma, Minh Hoang, Denis Leducq, Anthony Delahaye *Deep learning models for time series forecasting of indoor temperature and energy consumption in a cold room*, International Conference on

- Computational Collective Intelligence ICCCI 2019: Computational Collective Intelligence pp 133-144, 9 Agosto 2019, (cit pg. 64).
- [30] Hao Huang, Lei Chen, Morteza Mohammadzaheri, Eric Hu *A new zone temperature predictive modeling for energy saving in buildings*, Procedia Engineering Volume 49, 2012, Pages 142-151 , URL: <https://doi.org/10.1016/j.proeng.2012.10.122> , (cit pg. 65).
- [31] Sullivan Royer, Stéphane Thil, Thierry Talbert, Monique Polit *Black-box modeling of buildings thermal behavior using system identification*, IFAC Proceedings Volumes Volume 47, Issue 3, 2014, Pages 10850-10855, URL: <https://doi.org/10.3182/20140824-6-ZA-1003.01519> , (cit pg. 65, 66).
- [32] Francisco Zamora-Martinez, Pablo Romeu, Paloma Botella-Rocamora, Juan Pardo *Towards Energy Efficiency: Forecasting Indoor Temperature via Multivariate Analysis* , Energies 2013, 6, 4639-4659; doi:10.3390/en6094639, (cit pg. 66).
- [33] Zakia Afroz, Tania Urmee , G.M. Shafiullah , Gary Higgins *Real-time prediction model for indoor temperature in a commercial building*, Applied Energy Volume 231, 1 December 2018, Pages 29-53, URL: <https://doi.org/10.1016/j.apenergy.2018.09.052> , (cit pg. 67).
- [34] M.Killian, B.Mayer, M.Kozek *Effective fuzzy black-box modeling for building heating dynamics*, Energy and Buildings Volume 96, 1 June 2015, Pages 175-186, URL: <https://doi.org/10.1016/j.enbuild.2015.02.057> , (cit pg. 67).
- [35] Xiuming Li, Tianyi Zhao, Jili Zhang, Tingting Chen *Predication control for indoor temperature time-delay using Elman neural network in variable air volume system*, Energy and Buildings Volume 154, 1 November 2017, Pages 545-552, URL: <https://doi.org/10.1016/j.enbuild.2017.09.005> , (cit pg. 68).
- [36] Leopold Mba, Pierre Meukam, Alexis Kemajou *Application of artificial neural network for predicting hourly indoor air temperature and relative humidity in modern building in humid region*, Energy and Buildings Volume 121, 1 June 2016, Pages 32-42, URL: <https://doi.org/10.1016/j.enbuild.2016.03.046> , (cit pg. 68).
- [37] Qiong Liab, Qinglin Menga, Jiejun Caic, Hiroshi Yoshinob, Akashi Mochida *Applying support vector machine to predict hourly cooling load in the building*, Applied Energy Volume 86, Issue 10, October 2009, Pages 2249-2256, URL: <https://doi.org/10.1016/j.apenergy.2008.11.035> , (cit pg. 68, 69).
- [38] Chengliang Xu, Huanxin Chen, Jiangyu Wang, Yabin Guo, Yue Yuan *Improving prediction performance for indoor temperature in public buildings based on a novel deep learning method*, Building and Environment Volume 148, 15 January 2019, Pages 128-135, URL: <https://doi.org/10.1016/j.buildenv.2018.10.062> , (cit pg. 69).
- [39] A.E. Ruano, E.M. Crispim, E.Z.E. Conceicao, M.M.J.R. Lúcio *Prediction of building's temperature using neural networks models*, Energy

- and Buildings Volume 38, Issue 6, June 2006, Pages 682-694, URL: <https://doi.org/10.1016/j.enbuild.2005.09.007> , (cit pg. 69).
- [40] Bingqing Chen, Zicheng Cai, Mario Bergés *Gnu-RL: A Precocial Reinforcement Learning Solution for Building HVAC Control Using a Differentiable MPC Policy*, BuildSys '19: Proceedings of the 6th ACM International Conference on Systems for Energy-Efficient Buildings, Cities, and Transportation, November 2019 Pages 316–325, URL: <https://doi.org/10.1145/3360322.3360849> , (cit pg. 70).
- [41] Yize Chen, Yuanyuan Shi e Baosen Zhang “*Modeling and Optimization of Complex Building Energy Systems with Deep Neural Networks*” di Yize Chen, Yuanyuan Shi e Baosen Zhang, 2017 51st Asilomar Conference on Signals, Systems, and Computers, Pacific Grove, CA, USA, 2017, pp. 1368-1373, doi: 10.1109/ACSSC.2017.8335578. , (cit pg. 71).
- [42] Matthew J.Ellis, Venkatesh Chinde *An encoder–decoder LSTM-based EMPC framework applied to a building HVAC system*, Chemical Engineering Research and Design Volume 160, August 2020, Pages 508-520, URL: <https://doi.org/10.1016/j.cherd.2020.06.008> , (cit pg. 71, 72).
- [43] Francois Chollet et al. *Keras*, 2015, URL: <https://github.com/fchollet/keras> , (cit pg. 86).
- [44] Nitish Srivastava, Geoffrey Hinton, Alex Krizhevsky, Ilya Sutskever, Ruslan Salakhutdinov, *Dropout: A Simple Way to Prevent Neural Networks from Overfitting* , Journal of Machine Learning Research 15 (2014) 1929-1958 , (cit pg. 87, 88).
- [45] Jason Brownlee, *Dropout Regularization in Deep Learning Models With Keras*, Deep Learning, Machine Learning Mastery, 20 Giugno 2016, URL: <https://machinelearningmastery.com/dropout-regularization-deep-learning-models-keras/> , (cit pg. 87, 88).
- [46] Jason Brownlee, *How to Develop a Bidirectional LSTM For Sequence Classification in Python with Keras*, Long Short-Term Memory Networks, Machine Learning Mastery, 16 Giugno 2017, URL: <https://machinelearningmastery.com/develop-bidirectional-lstm-sequence-classification-python-keras/>, (cit pg. 87).
- [47] Mike Schuster, Kuldip K. Paliwal *Bidirectional Neural Networks*, IEEE Transactions on Signal Processing, Vol. 45, No. 11 Novembre 1997, (cit pg. 87).
- [48] Jason Brownlee, *Gentle Introduction to the Adam Optimization Algorithm for Deep Learning*, Deep Learning Performance, Machine Learning Mastery, 3 Luglio 2017, URL: <https://machinelearningmastery.com/adam-optimization-algorithm-for-deep-learning/> , (cit pg. 89).

- [49] Algorithmia, *Introduction to optimizers*, 7 Maggio 2018 , URL: <https://algorithmia.com/blog/introduction-to-optimizers> , (cit pg. 89).
- [50] Avinash Sharma V, *Understanding Activation Functions in Neural Networks*, The Theory of Everything, 30 Marzo 2017, URL: <https://medium.com/the-theory-of-everything/understanding-activation-functions-in-neural-networks-9491262884e0> , (cit pg. 88).
- [51] Tao Lu, Martti Viljanen, *Prediction of indoor temperature and relative humidity using neural network models: model comparison*, Neural Comput & Applic 18, 345 (2009). URL: <https://doi.org/10.1007/s00521-008-0185-3> , (cit pg. 194)
- [52] G.Mustafaraj, J.Chen, G.Lowry *Thermal behaviour prediction utilizing artificial neural networks for an open office*, Applied Mathematical Modelling Volume 34, Issue 11, November 2010, Pages 3216-3230, URL: <https://doi.org/10.1016/j.apm.2010.02.014> , (cit pg. 194).
- [53] Chernbumroong S, Lotfi A, Langensiepen C. *Prediction of mobility entropy in an Ambient Intelligent environment*, In: Intelligent agents (IA), 2014 IEEE Symposium on; 2014. p. 65–72, (cit pg. 194).