



UNIONE EUROPEA
Fondo Sociale Europeo
Fondo Europeo di Sviluppo Regionale



Avviso 1735 del 13.07.2017 MIUR

Progetti di Ricerca Industriale e Sviluppo Sperimentale nelle 12 Aree di Specializzazione individuate dal PNR 2015-2020

Sintesi delle caratteristiche testate mediante il tool di pianificazione e schede di test effettuati

Rapporto tecnico di Ricerca Industriale D8.1a



Avviso	Avviso 1735 del 13.07.2017 MIUR
Codice progetto	ARS01_01259
Nome del progetto	Community Energy Storage Gestione Aggregata di Sistemi di Accumulo dell'Energia in Power Cloud
Acronimo	ComESto
Documento	D8.1
Tipologia	Rapporto Tecnico
Data di rilascio	05/04/2022
Obiettivo Realizzativo	OR8
Attività Realizzativa	A8.1
Soggetti Beneficiari Proponenti	E-DISTRIBUZIONE
Elaborato (Nome, Cognome – Soggetto Beneficiario)	Francesco Dura, Maurizio Cinus, Roberto Infantino – E-DISTRIBUZIONE Gianvito Pio, Michelangelo Ceci – DHITECH
Verificato (Nome, Cognome – Soggetto Beneficiario)	Francesco Dura – E-DISTRIBUZIONE
Approvato (Nome, Cognome – Soggetto Beneficiario)	Membri del PEB

INDICE DEI CONTENUTI

EXECUTIVE SUMMARY.....	6
1. DESCRIZIONE ATTIVITÀ E RISULTATO ATTESO	6
1.1 Risultati sperimentali con profili di carica/scarica dei Sistemi di Accumulo e Generazione Distribuita 7	
1.1.1 Sintesi dei risultati	8
2. ANALISI KPI E RISULTATI DELL'OTTIMIZZATORE.....	9
2.1 Rete di test	9
2.2 Rete reale linea MT	12
2.2.1 Premesse.....	12
2.2.2 Ottimizzazione delle reti BT con focus sulle singole Cabine secondarie	13
2.2.3 Analisi risultati rete reale.....	18
3. APPLICAZIONE PARTE PREDITTIVA MACHINE LEARNING.....	22
3.1 Caratteristiche dei dataset	22
3.2 Setting sperimentale	23
3.3 Esperimenti Rete test	24
3.3.1 Valutazione autocorrelazione temporale.....	25
3.3.2 Valutazione autocorrelazione spaziale.....	32
3.4 Esperimenti Rete MT reale e cabine secondarie	36
3.5 Applicazione di Tecniche di Transfer Learning	39
4. CONCLUSIONI.....	40

Abbreviazioni ed acronimi

Abbreviazione/Acronimo	Testo Esteso
BT	Bassa Tensione
CS	Cabina Secondaria
KNN	K-Nearest Neighbors
KPI	Key Performance Indicator
MLP	Multilayer Perceptron
MT	Media Tensione
RSE	Relative Squared Error
SDA	Sistemi Di Accumulo

Indice delle figure

Figura 1 Nuova configurazione rete di test e percorso critico.....	8
Figura 2 Rete di test pre-ottimizzazione.....	10
Figura 3 Rete di test post ottimizzazione	11
Figura 4 Plot Cabina n° 1 pre ottimizzazione.....	14
Figura 5 Plot Cabina n°1 post ottimizzazione	15
Figura 6 Plot Cabina n°2 pre ottimizzazione.....	16
Figura 7 Plot Cabina n°2 post ottimizzazione	17
Figura 8 Occorrenze sotto KPI rami Cabina n°1 pre – post ottimizzazione	18
Figura 9 Occorrenze sotto KPI Nodi Cabina n°1 pre – post ottimizzazione.....	19
Figura 10 Occorrenze KPI Carico Cabina n°1 pre – post ottimizzazione.....	19
Figura 11 Occorrenze sotto KPI Rami Cabina n°2 pre – post ottimizzazione	20
Figura 12 Occorrenze sotto KPI Nodi Cabina n°2 pre – post ottimizzazione.....	21
Figura 13 Occorrenze KPI Carico Cabina n°2 pre – post ottimizzazione.....	21
Figura 14 Rete TEST BT, RSE Medio SELF12, Autocorrelazione temporale	26
Figura 15 Rete TEST BT, RSE Medio SELF36, Autocorrelazione temporale	27
Figura 16 Rete TEST BT, RSE Medio multi-step, Autocorrelazione temporale	27
Figura 17 Rete TEST BT, Test Friedman-Nemenyi Self12	28
Figura 18 Rete TEST BT, Test Friedman-Nemenyi Self36	28
Figura 19 Rete TEST BT, Test Friedman-Nemenyi multi-step.....	29
Figura 20 Rete TEST BT, Test Friedman-Nemenyi, confronto configurazioni autocorrelazione temporale	29
Figura 21 Rete TEST BT, valori reali-predetti multi-step cliente C1	31
Figura 22 Rete TEST BT, valori reali-predetti multi-step cliente C2	32
Figura 23 Rete TEST BT, RSE Medio SELF12, Autocorrelazione spaziale.....	33
Figura 24 Rete TEST BT, RSE Medio SELF36, Autocorrelazione.....	33
Figura 25 Rete TEST BT, RSE Medio multi-step, Autocorrelazione spaziale.....	34

Figura 26 Rete TEST BT, Test Friedman-Nemenyi, confronto configurazioni autocorrelazione spaziale e temporale	35
Figura 27 Rete TEST BT, valori reali-predetti multi-step & autocorrelazione spaziale	36
Figura 28 rete MT reale, Multi-Step/Multi-Step + PCNM (2014-2015-2016)	37
Figura 29 rete MT reale, Multi-Step/Multi-Step + PCNM (2017-2018-2019)	38
Figura 30 rete MT reale, Valori reali-predetti Multi-Step/Multi-Step + autocorrelazione spaziale.....	38
Figura 31 rete MT reale, Valori reali-predetti Multi-Step/Multi-Step + autocorrelazione spaziale.....	39

Indice delle tabelle

Tabella 1 KPI pre ottimizzazione rete TEST	11
Tabella 2 Lista interventi ottimizzazione su rete TEST	12
Tabella 3 KPI post ottimizzazione rete TEST	12
Tabella 4 Lista interventi ottimizzazione rete reale: Cabina MT-BT n° 1.....	15
Tabella 5 lista interventi ottimizzazione rete reale: Cabina MT-BT n° 2	17
Tabella 6 Istanti critici pre – post ottimizzazione Cabina n°1.....	18
Tabella 7 Istanti critici pre – post ottimizzazione Cabina n°2.....	20
Tabella 8 Feature estratte dai dataset	23
Tabella 9 Risultati ottenuti tramite transfer learning rete MT reale->rete test.....	40
Tabella 10 Risultati ottenuti tramite transfer learning rete test -> rete MT reale.....	40

EXECUTIVE SUMMARY

In AR 8.1_a viene trattata l'analisi e la validazione dei risultati prodotti dal tool sviluppato nell'OR6, prendendo in considerazione diversi casi studio.

Le simulazioni sono state condotte in prima battuta su una rete di test, in modo tale da rendere poi confrontabili i risultati ottenuti con una porzione di rete reale MT costituita da 12 cabine secondarie, su cui in seconda battuta è stata estesa l'analisi.

Le simulazioni partono con la valutazione dello stato della rete attraverso opportuni KPI e, mediante l'applicazione di un ottimizzatore basato su funzioni obiettivo multiple, vengono proposti degli interventi migliorativi per ottimizzare la rete e quindi le performance con relativo riscontro nel miglioramento del KPI. Nella valutazione del beneficio tecnico l'ottimizzatore tiene conto di logiche economiche preimpostabili.

Le analisi condotte e il riscontro dei benefici ottenuti non possono prescindere da una attenta valutazione della tensione ai nodi della rete e dello sfruttamento dei conduttori che costituiscono i rami della rete analizzata. Pertanto, per avere subito un riscontro grafico dei risultati, tutti i plot della rete riportati mostrano in modo chiaro queste informazioni.

Come verrà mostrato nella valutazione sperimentale, l'ottimizzatore ha sempre dimostrato di migliorare in modo consistente la rete elettrica. Si precisa che le condizioni della rete di test sono più severe rispetto ai casi di rete reale proprio per la consistente presenza di generazione distribuita, comunità energetiche e sistemi di accumulo che, per essere integrati nella rete, richiedono diversi interventi strutturali.

1. DESCRIZIONE ATTIVITÀ E RISULTATO ATTESO

In questo capitolo vengono analizzati i risultati sperimentali ottenuti sulla base delle analisi e ottimizzazioni eseguite da UNICAL, relative a profili di carica e scarica ottimizzati degli storage, presenza di carichi e generazione distribuita sulla rete di distribuzione di bassa tensione della rete di test BT nel giorno più critico dell'anno in termini di carico sulla rete, risultato essere il 3 Agosto 2019. Tale giorno è stato individuato mediante load flow dell'intero anno.

Sulla base di questi profili comprensivi di servizi, sono stati valutati i KPI della rete prima e dopo l'intervento dell'ottimizzatore messo a punto da DHITECH.

Si ricorda a tal proposito che l'ottimizzatore considera eventuali vincoli di budget e restituisce una serie di soluzioni identificandone poi una come la migliore; nel dettaglio questo aspetto verrà approfondito nella sezione 2.1.

Il sistema di ottimizzazione prende in considerazione le seguenti funzioni obiettivo:

1. Minimizzazione della massima differenza di tensione rispetto a quella nominale ;
2. Minimizzazione del livello di carico massimo sui conduttori BT della rete elettrica;
3. Minimizzazione del livello di carico massimo sui trasformatori MT/BT della rete elettrica;

4. Minimizzazione del rapporto tra il numero totale dei carichi e il numero delle linee BT;
5. Minimizzazione della varianza delle quantità dei carichi sulle linee BT.

Il sistema di ottimizzazione ha a disposizione i seguenti interventi:

- Installazione di un nuovo trasformatore;
- Sostituzione di un trasformatore con un altro di maggiore potenza;
- Installazione di un nuovo conduttore;
- Allargamento della sezione di un conduttore esistente;
- Creazione di una nuova linea.

1.1 Risultati sperimentali con profili di carica/scarica dei Sistemi di Accumulo e Generazione Distribuita

Questo paragrafo ha lo scopo di creare un legame tra i vari studi messi a punto dai partner del progetto ComESto. In particolare verrà descritto come sono stati coordinati gli studi condotti da Unical e DHITECH al fine di poter testare e migliorare la rete di test fornita da E-distribuzione, successivamente adeguata allo scopo del progetto di comunità energetiche da Unical, che ha inserito generatori fotovoltaici distribuiti e accumulatori.

In linea con i futuri sviluppi delle reti verso una generazione distribuita e l'incremento degli storage elettrici che consentiranno a tutti gli utenti di dare un fattivo supporto alla rete, sono stati trasformati in modo mirato i semplici utenti consumatori in Prosumers. Successivamente, in ottica evolutiva, si sono dotati questi utenti prosumers di sistemi di accumulo centralizzati o distribuiti al fine di verificare gli effetti sulla rete in esame. Tutta questa fase di trasformazione attiva della rete, e di studio della miglior applicazione del meccanismo di carica e scarica dei sistemi di accumulo, è stato eseguito in sinergia tra Unical e DHITECH.

Da questo studio è emerso che per la risoluzione di una problematica sulla rete all'occorrenza è possibile sfruttare le potenzialità della generazione distribuita in alternativa o in aggiunta ad interventi classici di pianificazione di rete con intervento su nuove infrastrutture.

In definitiva, la rete di distribuzione di test in bassa tensione che è stata studiata ha le seguenti caratteristiche:

- parte da una cabina secondaria (CS);
- è costituita da due linee BT;
 - ❖ le due linee complessivamente contano 137 nodi, 135 rami, 154 utenti di cui 15 Prosumers e 139 consumers;
 - ❖ il carico totale è pari a 675 kW;
 - ❖ la generazione totale è pari ad 86,28 kW.

In Figura 1 è rappresentata la seconda linea, sulla quale sono state introdotte le comunità energetiche.

In particolare,

- nel cluster A1 sono stati aggiunti 42 kW di impianti distribuiti sugli utenti e 60 kWh di sistemi di accumulo; difatti quasi tutti gli utenti hanno beneficiato di una completa trasformazione tecnologica
- nel cluster A2 è stato aggiunto un impianto di generazione centralizzato da 40 kW e 64 kWh di sistemi di accumulo
- nel cluster A3 sono stati aggiunti 20 kW di impianto di generazione centralizzato e 40 kWh di sistemi di accumulo

In riferimento alla gestione dei sistemi di accumulo, il criterio in base al quale sono stati determinati i profili di carica e scarica è stato messo a punto da Unical mediante uno studio che ha privilegiato come funzione obiettivo la massima convenienza per il cliente in termini di prezzo di acquisto e vendita dell'energia; il modello OFISDA+DRPG (descritto in dettaglio del rapporto tecnico di AR 5.2) prevede la generazione di profili ottimizzati di carica e scarica degli accumulatori al litio al fine di ridurre le criticità e ottimizzare i costi totali.

È stato previsto inoltre uno stanziamento di $\frac{1}{4}$ dell'energia totale disponibile nelle batterie da dedicare ai servizi ancillari di rete al fine di sopperire alle situazioni estreme

- di maggior carico e assenza di produzione (ore notturne)
- minor carico e massima produzione (ore diurne)

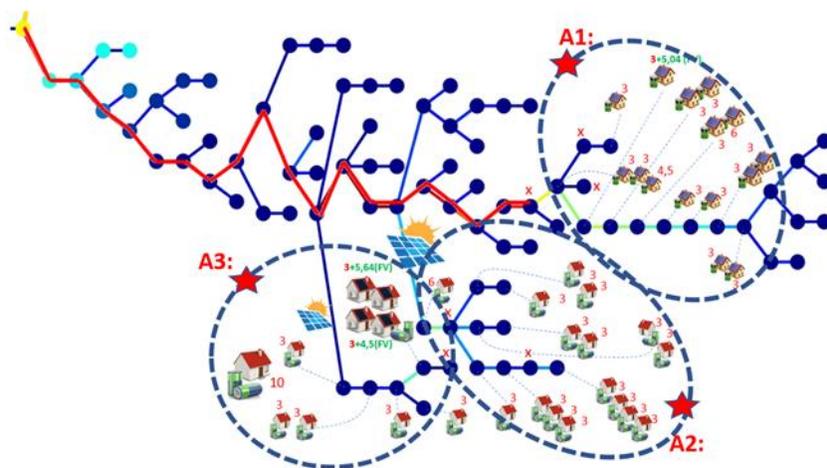


Figura 1 Nuova configurazione rete di test e percorso critico.

In definitiva, partendo dall'assetto ottimizzato con impianti di produzione e sistemi di accumulo descritto in dettaglio in AR5.2, verranno qui di seguito analizzati e rendicontati i risultati sperimentali ottenuti sulla rete test, misurando i KPI pre e post-intervento dell'ottimizzatore.

1.1.1 Sintesi dei risultati

In riferimento alla rete di test appena descritta, la situazione pre intervento presentava dei valori di tensione eccessivamente bassi, soprattutto nella fascia oraria 12:30-17:30 (33% delle occorrenze sono critiche, il che significa valori di tensione < -10%).

Le soglie di allerta includono valori compresi tra -5% e -10%, le soglie di attenzione includono valori > - 5% .

Per poter studiare gradualmente l'impatto della generazione distribuita sulla rete, l'evoluzione dei clienti da consumatori a prosumer mediante creazione di comunità energetiche, è stata suddivisa in due step:

- 1^ step: inserimento degli impianti fotovoltaici
- 2^ step: inserimento di impianti fotovoltaici più batterie

A seguito del primo test il valore delle tensioni basse si è ridotto notevolmente interessando un numero di situazioni critiche pari al 18% delle occorrenze.

Come prevedibile la generazione distribuita ha portato anche qualche caso di innalzamento della tensione (5% delle occorrenze) oltre il +10% (soglia critica superiore). Si può quindi concludere che l'effetto benefico degli impianti fotovoltaici è stato molto maggiore rispetto a qualche piccola ripercussione.

A seguito del secondo test la situazione pre intervento del 33% di tensioni critiche inferiormente scende all'11% mentre le situazioni critiche superiormente si riducono rispetto al test 1 dal 5% al 4%.

Si rileva che i benefici dell'inserimento degli impianti fotovoltaici e sistemi di accumulo ha avuto sia l'effetto di ridurre i campioni temporali interessati, sia soprattutto di ridurre numericamente le occorrenze che si sono verificate.

2. ANALISI KPI E RISULTATI DELL'OTTIMIZZATORE

2.1 Rete di test

Di seguito vengono riepilogati i passaggi eseguiti per la valutazione e l'ottimizzazione della rete di test:

- 1) Viene fornita la rete di test con i profili di carico.
- 2) Sulla rete di test vengono integrate le comunità energetiche inserendo i profili delle batterie e degli impianti di generazione distribuita con i criteri sintetizzati in 1.1.
- 3) Sulla rete definita al punto 2 vengono calcolati i seguenti KPI: Struttura, Carico e Affidabilità della Regolazione.
- 4) Viene individuato l'istante più critico dell'anno attraverso il KPI di Carico.
- 5) Entra in gioco l'ottimizzatore che, partendo dalla fotografia settata con i profili di produzione, consumo e batterie relativi all'istante più critico individuato nel punto precedente, fornisce un nuovo assetto della rete.
- 6) Si analizzano le soluzioni restituite dall'ottimizzatore e si sceglie la soluzione migliore.
- 7) Sulla soluzione migliore definita al punto 6 vengono ricalcolati i KPI menzionati al punto 3 e, in aggiunta, il KPI di Hosting Capacity.

A seguito di diversi esperimenti preliminari, si è constatato che il miglior compromesso tra qualità del risultato e tempo necessario per l'elaborazione, consiste nel settare l'ottimizzatore con i seguenti parametri:

- ✓ 15 interventi;
- ✓ 70k iterazioni;
- ✓ 200k euro di budget.

Il sistema di ottimizzazione ha prodotto in output 38 soluzioni genuine (considerate accettabili rispetto alle soglie delle funzioni obiettivo).

L’algoritmo di ottimizzazione ha dunque selezionato la miglior soluzione tra quelle proposte utilizzando il Fuzzy Satisfying Method. Questo metodo, come suggerisce il nome, si fonda sulla Logica Fuzzy, basata sui concetti di insiemistica e sulla funzione di membership definita come:

$$\mu_i = \begin{cases} 1 & F_i \leq F_i^{min} \\ \frac{F_i^{max} - F_i}{F_i^{max} - F_i^{min}} & F_i^{min} < F_i < F_i^{max} \\ 0 & F_i \geq F_i^{max} \end{cases}$$

L’algoritmo utilizza il metodo fuzzy nel seguente modo:

- a) Per ogni funzione obiettivo viene individuato il valore massimo e il valore minimo osservato
- b) Per ogni soluzione viene applicata la funzione di membership nel seguente modo:

I risultati delle funzioni obiettivo e del costo di ogni soluzione vengono confrontati con il valore massimo e il valore minimo ottenuti al punto 1. Se:

- i. il risultato i-esimo è pari al valore minimo, la funzione di membership (fuzzyness) avrà valore 1;
- ii. il risultato i-esimo è pari al valore massimo, la fuzzyness avrà valore 0;
- iii. il risultato i-esimo è compreso strettamente tra il valore massimo e il valore minimo, la fuzzyness avrà valore pari al risultato della seguente espressione di normalizzazione dei valori [valore massimo – risultato i-esimo] / [valore massimo-valore minimo];

- c) Per ogni riga (soluzione) vengono sommati i valori della fuzzyness ottenuti al punto precedente;
- d) Si calcola la somma dei valori (fuzzyness);
- e) La soluzione che ottiene il valore massimo rappresenta la soluzione migliore.

Di seguito sono riportati i risultati ottenuti pre-ottimizzazione e post-ottimizzazione.

➤ Pre-ottimizzazione

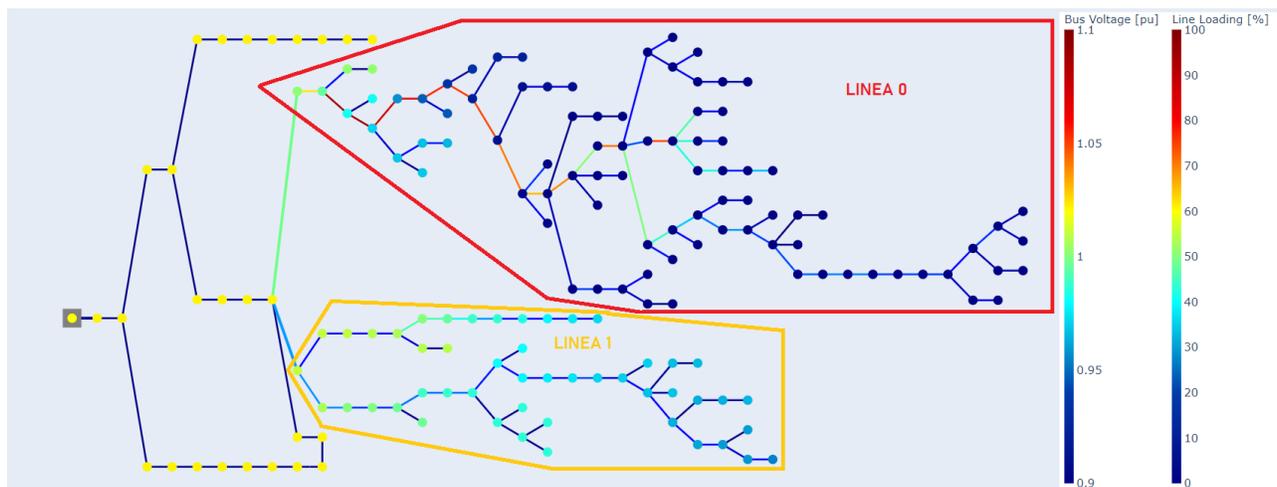


Figura 2 Rete di test pre-ottimizzazione

RISULTATI KPI PRE-OTTIMIZZAZIONE		
KPI	RISULTATI	
	Linea 0	Linea 1
Struttura	4.55	3.45
Carico	5	
Affidabilità e Regolazione	Linea 0	Linea 1
	5	Linea senza storage (KPI non applicabile)

Tabella 1 KPI pre ottimizzazione rete TEST

➤ Post-ottimizzazione

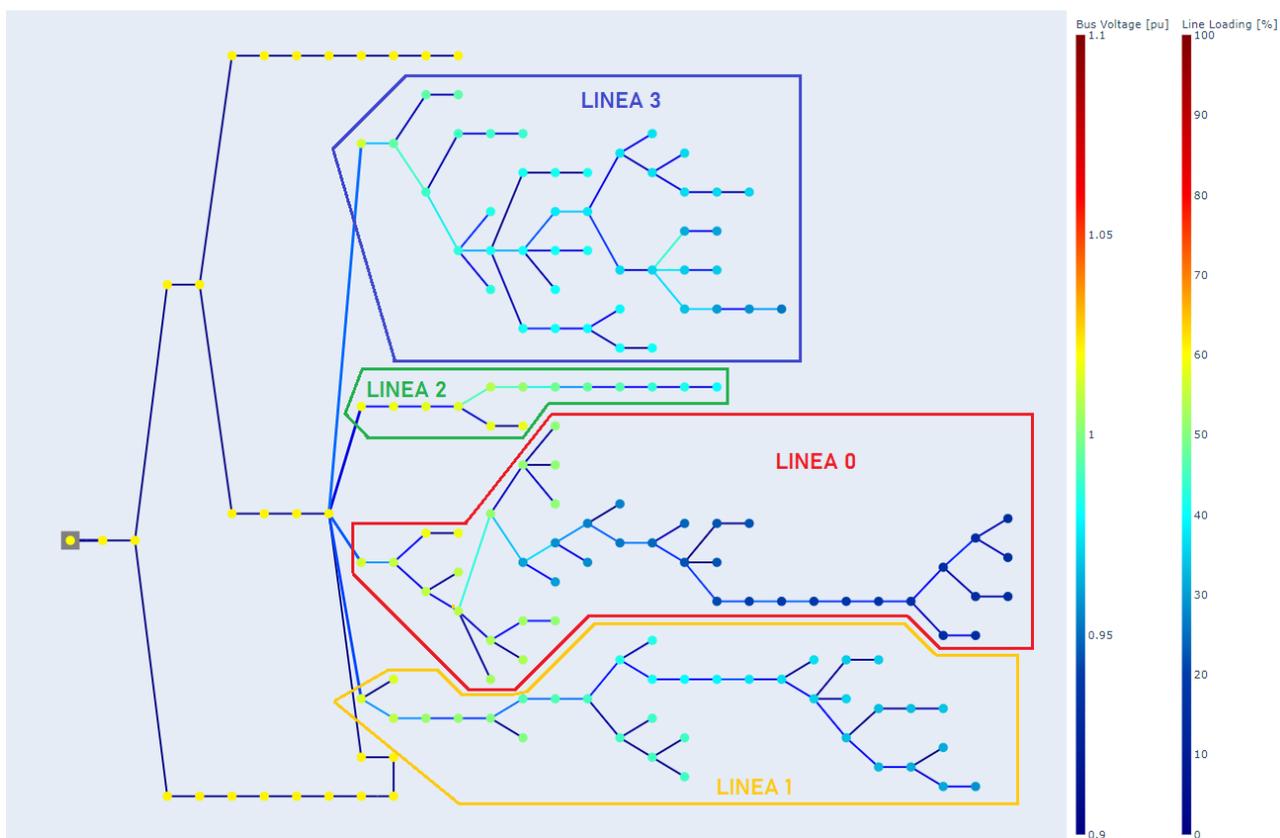


Figura 3 Rete di test post ottimizzazione

Di seguito vengono riportati gli interventi migliorativi suggeriti dall'ottimizzatore per la rete di Test BT

- il carico che prima era sulla linea 1 viene distribuito sulla linea 1 e linea 2 mediante nuovo interruttore in cabina secondaria (interruttore di linea 2)
- il carico che prima era sulla linea 0 viene distribuito sulla linea 0 e linea 3 mediante nuovo interruttore in

cabina secondaria (interruttore di linea 3) e riassetto del carico sulla rete di bassa tensione

- nuovo raccordo linea per riassetto linea 1 e 2
- nuovo raccordo linea per riassetto linea 0 e 3
- allargamento sezione di 4 rami su linee Bt

N°	Cabina rete test BT	
	Nome Intervento	Dettagli
1	Nuovo interruttore in cabina secondaria per nuova linea BT	Divisione della linea
2	Nuovo interruttore in cabina secondaria per nuova linea BT	Divisione della linea
3	Nuovo raccordo linea per riassetto linea	Nuovo ramo
4	Nuovo raccordo linea per riassetto linea	Nuovo ramo
5	Nuovo raccordo linea per riassetto linea	Nuovo ramo
6	Allargamento sezione ramo BT	Allargamento Sezione cavo
7	Allargamento sezione ramo BT	Allargamento Sezione cavo
8	Allargamento sezione ramo BT	Allargamento Sezione cavo
9	Allargamento sezione ramo BT	Allargamento Sezione cavo

Tabella 2 Lista interventi ottimizzazione su rete TEST

RISULTATI KPI POST-OTTIMIZZAZIONE				
KPI	RISULTATI			
	<u>Linea 0</u>	<u>Linea 1</u>	<u>Linea 2</u>	<u>Linea 3</u>
Struttura	4.15	3.05	1.3	3.0
Carico	3			
	<u>Linea 0</u>	<u>Linea 1</u>	<u>Linea 2</u>	<u>Linea 3</u>
Affidabilità e Regolazione	0	senza storage (KPI non applicabile)	senza storage (KPI non applicabile)	0 senza storage (KPI non applicabile)
	<u>Linea 0</u>	<u>Linea 1</u>	<u>Linea 2</u>	<u>Linea 3</u>
Hosting Capacity	1	1	1	1
<i>Tutti i nodi di tutte le linee sono in fascia F1</i>				

Tabella 3 KPI post ottimizzazione rete TEST

2.2 Rete reale linea MT

2.2.1 Premesse

Il presente studio è consistito nella gestione separata delle singole cabine secondarie (MT-BT) appartenenti ad una linea MT reale, prese singolarmente in analogia con quanto fatto sulla rete di test. Dunque, per ogni cabina verranno determinati i KPI pre e post intervento dell'ottimizzatore, andando ad eliminare le criticità dovute a congestione della rete o cadute di tensione eccessive.

2.2.2 Ottimizzazione delle reti BT con focus sulle singole Cabine secondarie

Come specificato per la rete di test, alla base gli studi si basano su un primo load flow con i consumi reali. Chiaramente l'ottimizzatore lavora laddove siano rilevate criticità nel KPI di carico.

Per la rete reale oggetto di studio, questo primo load flow ha riscontrato una rete in cui soltanto pochi interventi sarebbero dovuti essere effettuati, poiché nativamente non critica; pertanto per testare tutte le funzionalità possibili dell'ottimizzatore ai fini della simulazione per questo obiettivo realizzativo si è scelto di incrementare il carico moltiplicando per un coefficiente i consumi reali.

I risultati che verranno mostrati da qui in avanti faranno quindi riferimento a questo nuovo scenario di simulazione.

La linea MT reale oggetto di test è costituita da 12 cabine secondarie MT-BT.

Tali cabine sono state gestite in analogia a quanto avvenuto per la rete test (descrizione riportata nel paragrafo 2.1), ossia analizzate, valutate attraverso i relativi KPI e ottimizzate a livello di intervento sulla BT (l'unico intervento MT, se necessario, si limita ad aggiungere un trasformatore o potenziare quello esistente in cabina secondaria).

Nel presente capitolo verranno analizzati in dettaglio i risultati delle cabine più significative, con evidenza dei KPI pre e post intervento dell'ottimizzatore e rispettive soluzioni migliorative proposte.

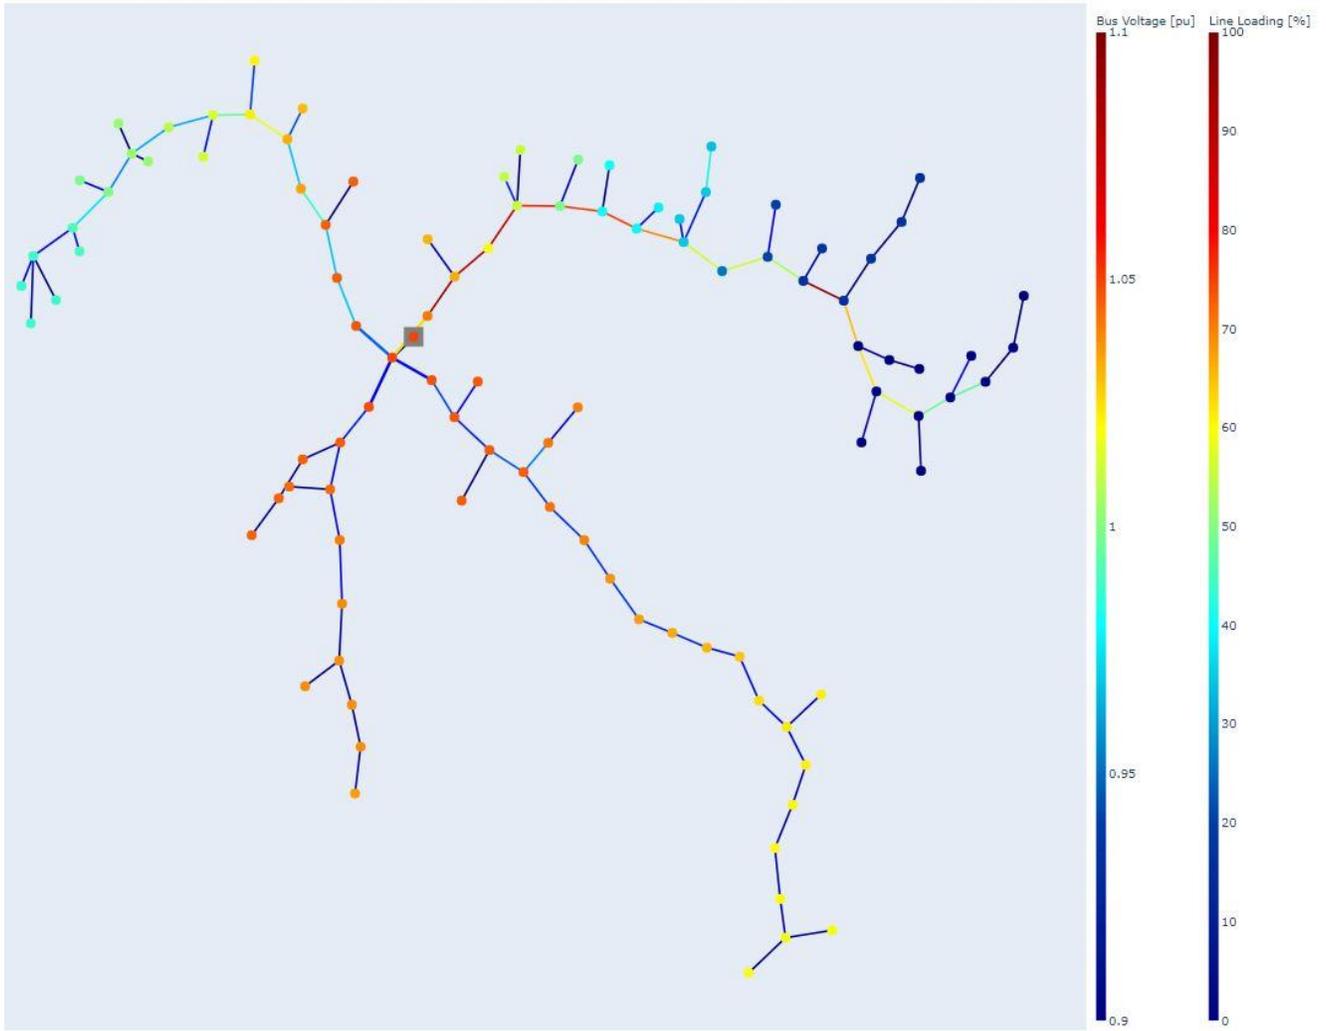


Figura 4 Plot Cabina n° 1 pre ottimizzazione

KPI		Cabina n°1		KPI	
Pre Ottimizzazione		N°	Nome intervento	Post Ottimizzazione	
Struttura	[2.55, 2.15, 3.4, 2.05]	1	Nuovo interruttore in cabina secondaria	Struttura	[0.8, 2.15, 3.4, 0.8, 1.25, 1.7, 2.2]
Carico	[5]	2	Nuovo interruttore in cabina secondaria	Carico	[5]
HC	[1, 1, 5, 1]	3	Nuovo interruttore in cabina secondaria	HC	[1, 1, 1, 1, 5, 1, 3]
Istante Critico	37 - 01/11/2019 09:30	4	Potenziamento del Trasformatore	Istante Critico	2478 - 26/11/2019 19:30
			Dettagli		
			Divisione della linea		
			Divisione della linea		
			Divisione della linea		
			Rimpiazzo trasformatore		

Tabella 4 Lista interventi ottimizzazione rete reale: Cabina MT-BT n° 1

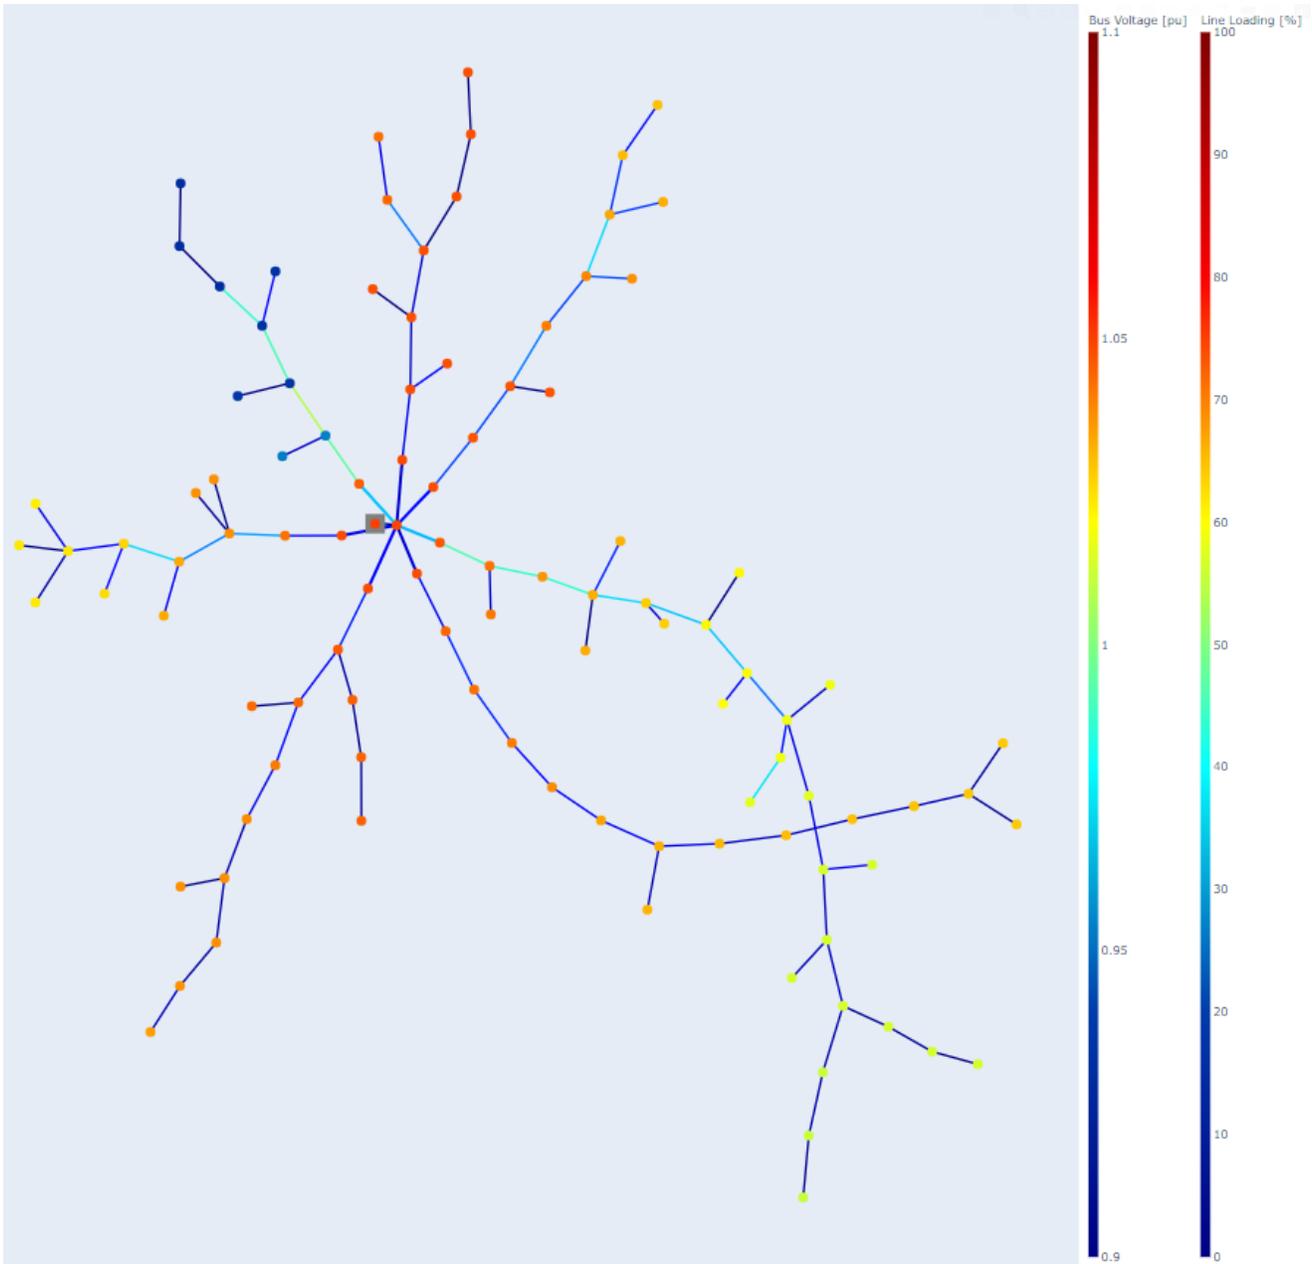


Figura 5 Plot Cabina n°1 post ottimizzazione

Già da una preliminare analisi grafica dei plot si rileva come, confrontando Figura 4 e Figura 5, i nodi blu scuro con tensione intorno a 0.9 p.u. e i rami rossi con sfruttamento maggiore dell'80% sono scomparsi quasi completamente a seguito degli interventi eseguiti dall'ottimizzatore.

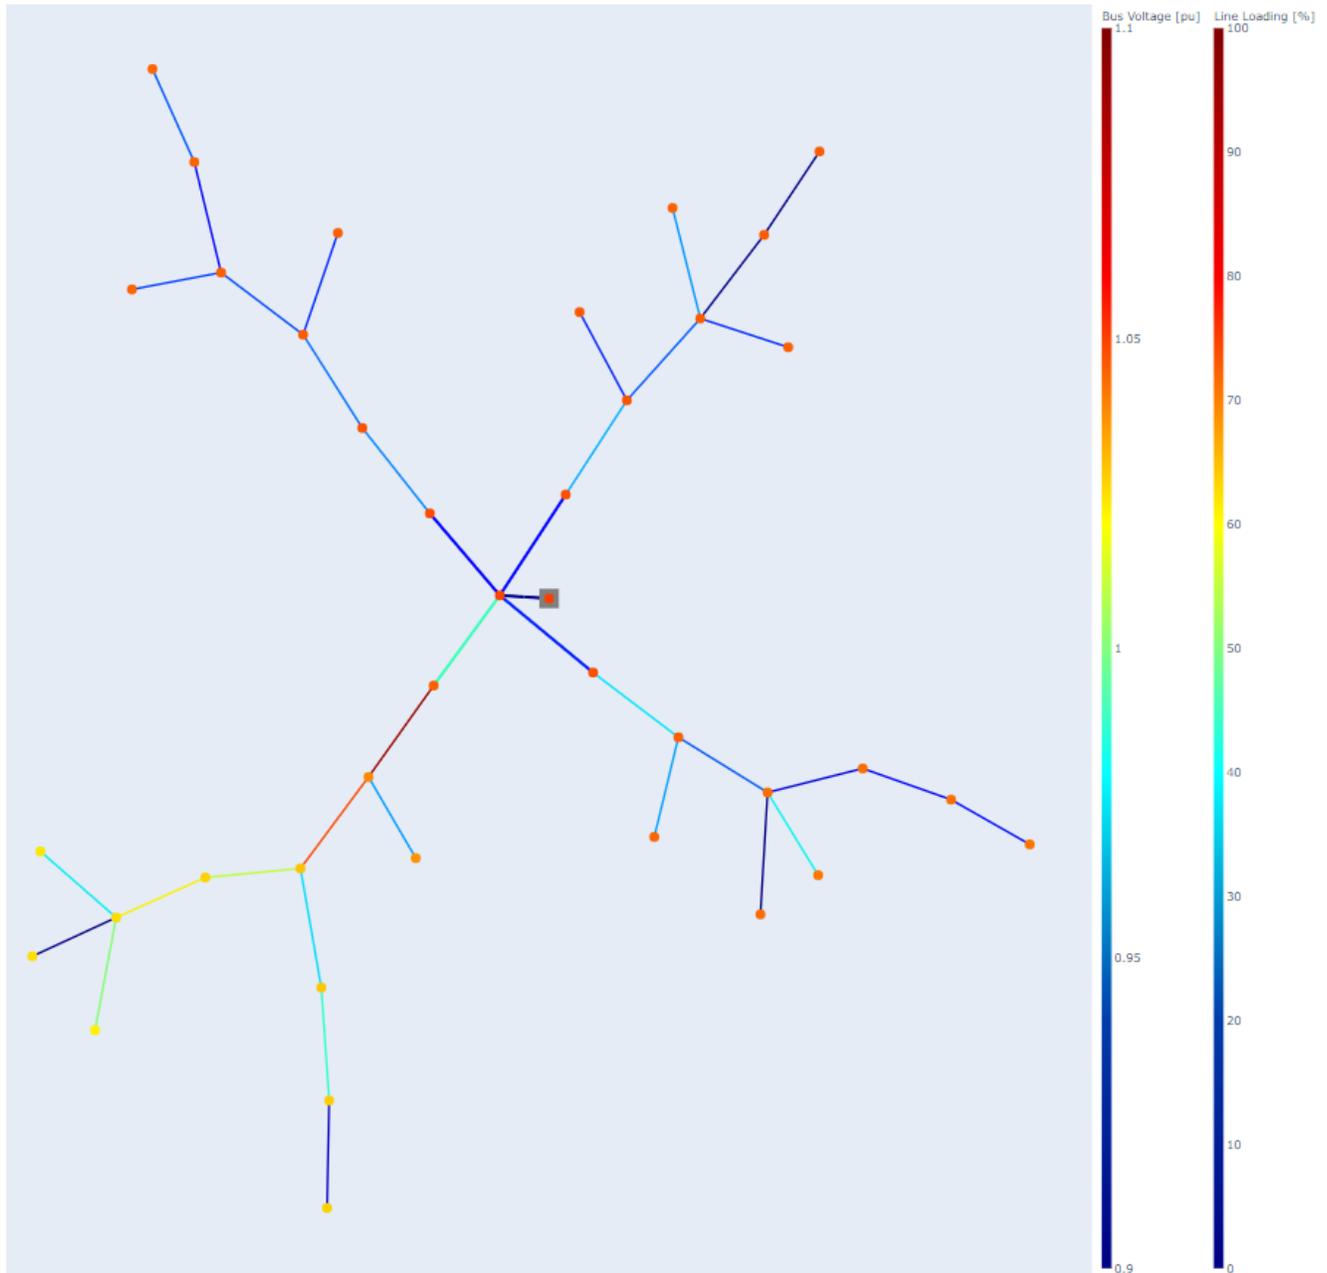


Figura 6 Plot Cabina n°2 pre ottimizzazione

KPI		Cabina n°2		KPI	
Pre Ottimizzazione		N°	Nome Intervento	Post Ottimizzazione	
Struttura	[2.2, 1.6, 1.6, 2.0]	1	Nuovo interruttore in cabina secondaria	Struttura	[1.4, 0.8, 1.2, 1.2, 1.2, 0.8, 0.8]
Carico	[5]	2	Nuovo interruttore in cabina secondaria	Carico	[2]
HC	[1, 1, 1, 5]	3	Nuovo interruttore in cabina secondaria	HC	[1, 1, 1, 1, 3, 1, 1, 1]
Istante Critico	174 - 02/11/2019 19:30	4	Nuovo interruttore in cabina secondaria	Istante Critico	1588 - 17/11/2019 13:00
			Dettagli		
			Divisione della linea		
			Divisione della linea		
			Divisione della linea		
			Divisione della linea		

Tabella 5 lista interventi ottimizzazione rete reale: Cabina MT-BT n° 2

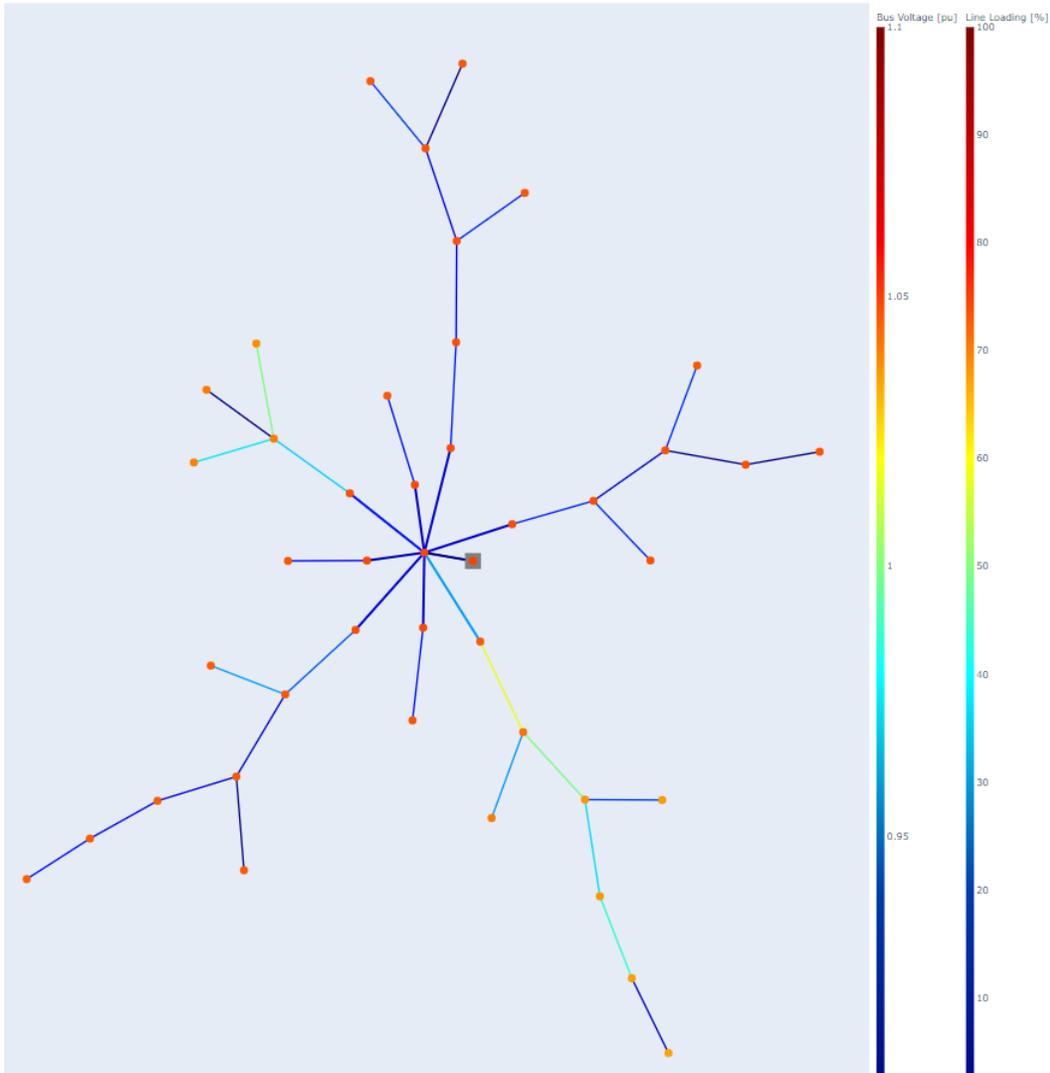


Figura 7 Plot Cabina n°2 post ottimizzazione

In questo caso già nella situazione di partenza non vi erano nodi critici come evidenziato in Tabella 7, tuttavia l'ottimizzatore è fondamentale per risolvere la criticità sui rami; era presente infatti un ramo con sfruttamento 80%, risolto dopo l'intervento dell'ottimizzatore.

2.2.3 Analisi risultati rete reale

Per poter apprezzare maggiormente i benefici che l’ottimizzatore ha apportato alla rete reale è interessante analizzare non soltanto il KPI complessivo ma anche il numero di occorrenze nelle varie fasce di criticità; a tal proposito, Tabella 6 e Tabella 7 e da Figura 8 a Figura 13 indicano per le due cabine più significative della analisi il numero di quarti d’ora dell’anno in cui si ricade nelle varie fasce.

Cabina n°1						
KPI Carico PRE Ottimizzazione: 5						
KPI Carico POST Ottimizzazione: 5						
KPI	Occorrenze sKPI Nodi		Occorrenze sKPI Rami		Occorrenze KPI Carico	
	Occorrenze Istanti Pre OTT	Occorrenze Istanti Post OTT	Occorrenze Istanti Pre OTT	Occorrenze Istanti Post OTT	Occorrenze Istanti Pre OTT	Occorrenze Istanti Post OTT
KPI 5	267	0	400	22	400	22
KPI 4	0	0	179	16	179	16
KPI 3	0	0	882	283	882	283
KPI 2	0	0	309	516	309	516
KPI 1	70	264	0	0	0	135
KPI 0	2543	2616	1110	2043	1110	1908

Tabella 6 Istanti critici pre – post ottimizzazione Cabina n°1

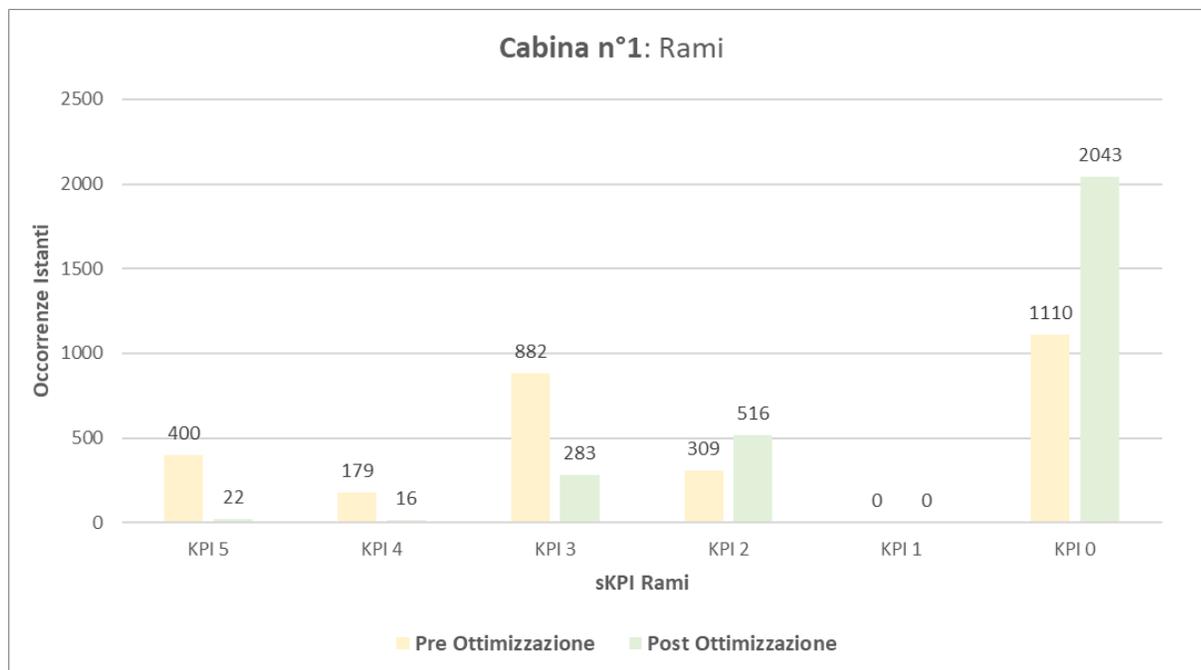


Figura 8 Occorrenze sotto KPI rami Cabina n°1 pre – post ottimizzazione

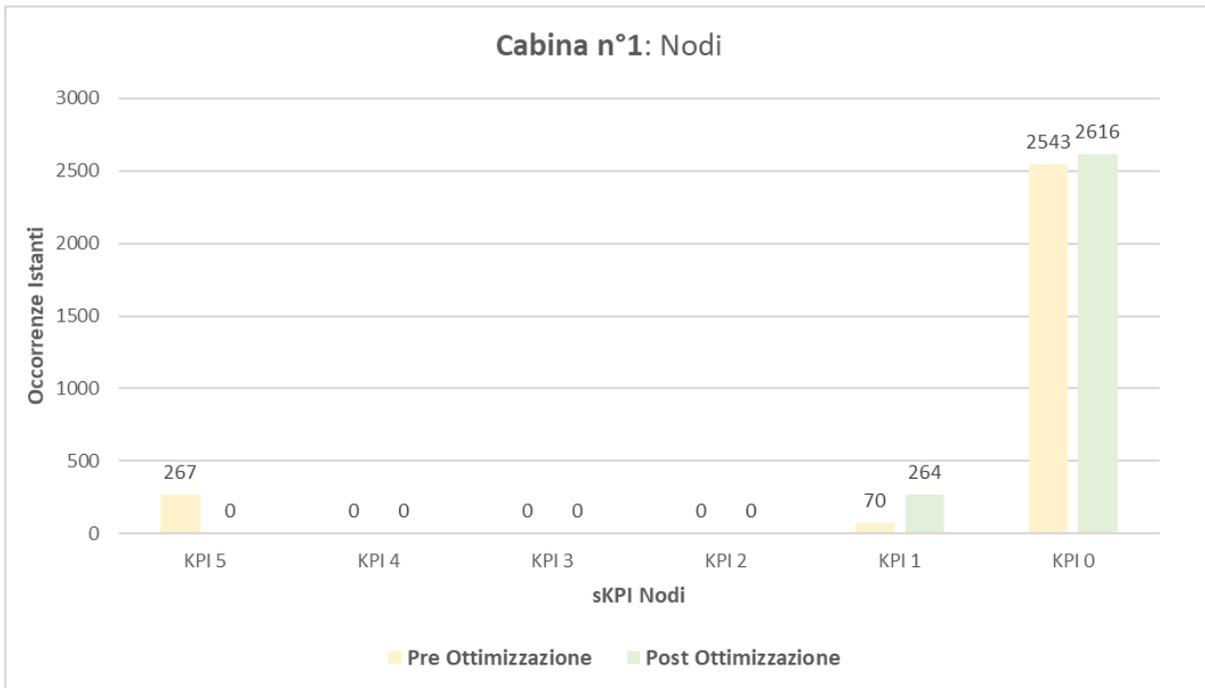


Figura 9 Occorrenze sotto KPI Nodi Cabina n°1 pre – post ottimizzazione

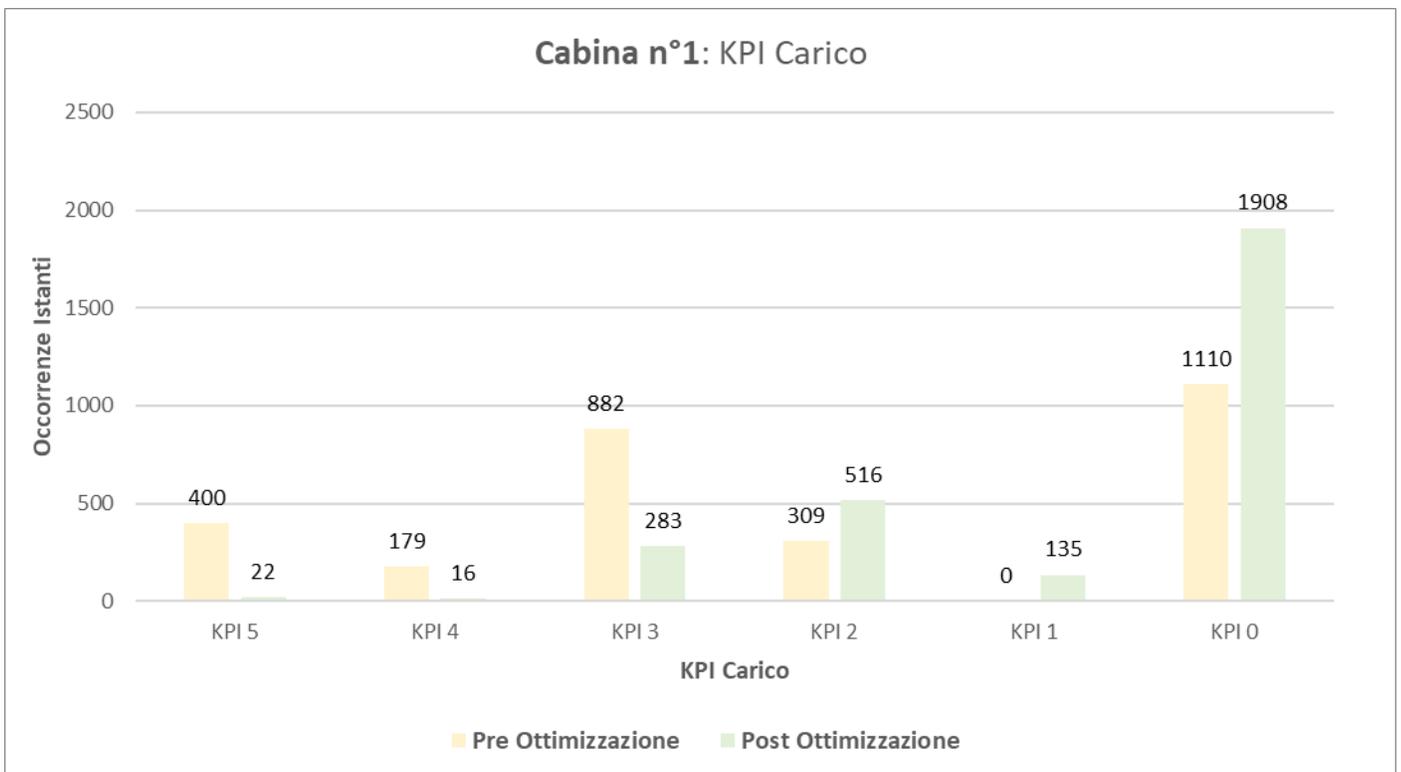


Figura 10 Occorrenze KPI Carico Cabina n°1 pre – post ottimizzazione

Cabina n°2										
KPI Carico PRE Ottimizzazione: 5										
KPI Carico POST Ottimizzazione: 2										
KPI	Occorrenze sKPI Nodi				Occorrenze sKPI Rami				Occorrenze KPI tot	
	Occorrenze		Occorrenze		Occorrenze		Occorrenze		Occorrenze	Occorrenze
	Istanti	Pre	Istanti	Post	Istanti	Pre	Istanti	Post	Istanti	Post
	OTT		OTT		OTT		OTT		OTT	
KPI 5	0		0		7		0		7	0
KPI 4	0		0		19		0		19	0
KPI 3	0		0		194		0		194	0
KPI 2	0		0		320		5		320	5
KPI 1	0		0		0		0		0	0
KPI 0	2880		2880		2340		2875		2340	2875

Tabella 7 Istanti critici pre – post ottimizzazione Cabina n°2

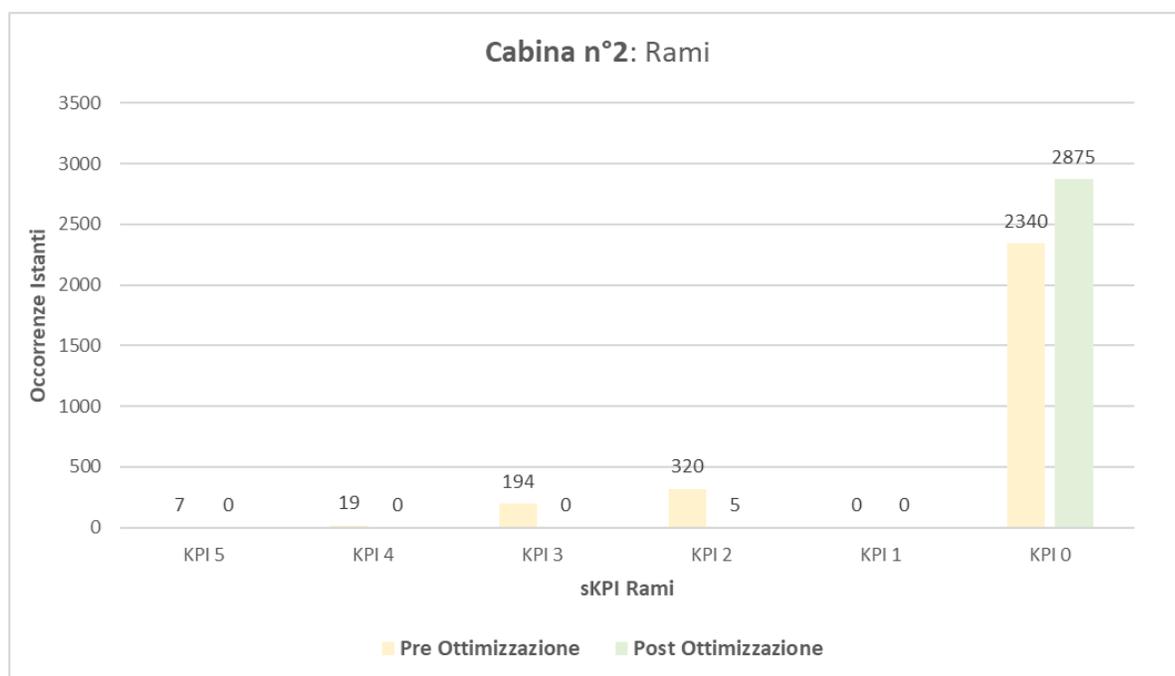


Figura 11 Occorrenze sotto KPI Rami Cabina n°2 pre – post ottimizzazione

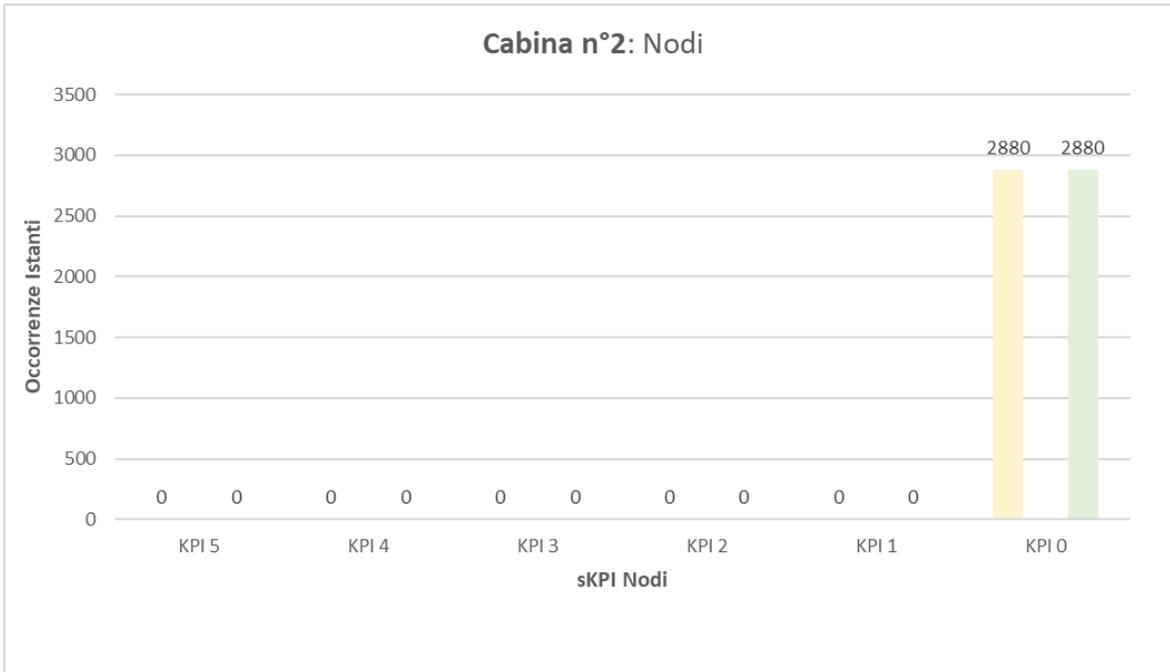


Figura 12 Occorrenze sotto KPI Nodi Cabina n°2 pre – post ottimizzazione

■ Pre Ottimizzazione ■ Post Ottimizzazione

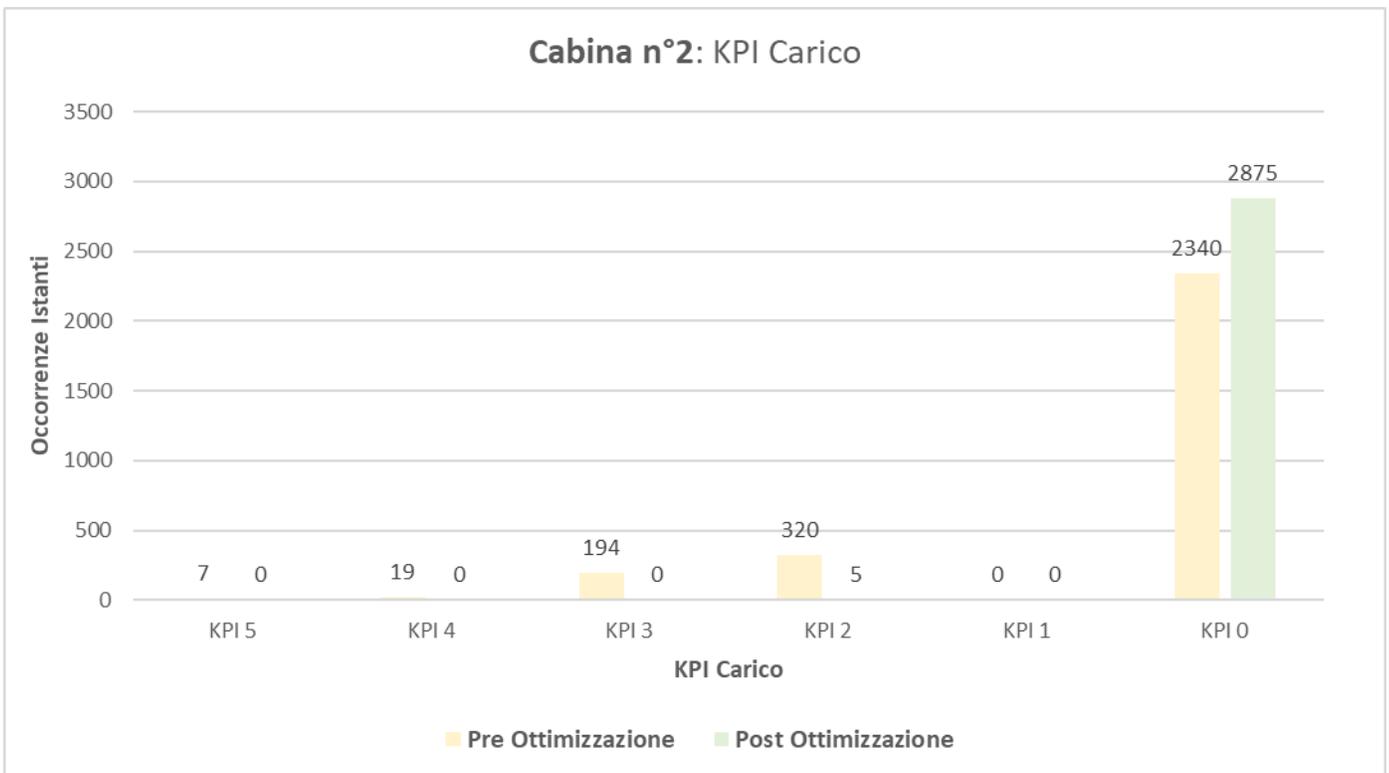


Figura 13 Occorrenze KPI Carico Cabina n°2 pre – post ottimizzazione

3. APPLICAZIONE PARTE PREDITTIVA MACHINE LEARNING

Nella sperimentazione condotta, sono state investigate due strategie single-step per la predizione di un solo valore (consumo) per ciascun cliente e una multi-step per la predizione in blocco di più valori target. In entrambi i casi sono state adottate soluzioni basate su sliding window, utilizzando come feature descrittive del modello le 12 misurazioni precedenti.

La prima configurazione single-step , di seguito denominata “SELF12”, è strutturata come segue.

- Feature Descrittive:
 - o 12 feature relative ai consumi dei 12 mesi precedenti
 - o Anno e mese della misurazione target

- Feature Target:
 - o Consumo del mese target

La seconda configurazione single-step, di seguito denominata “SELF36”, prevede anche le feature temporali relative ad anno e mese delle 12 misurazioni precedenti.

- Feature Descrittive:
 - o 12 feature relative ai consumi dei 12 mesi precedenti
 - o 12 feature anno
 - o 12 feature mese
 - o Anno e mese della misurazione target

- Feature Target:
 - o Consumo del mese target

Nella configurazione multi-step ciascuna osservazione è rappresentata dai consumi di un cliente di un determinato anno, a cui si aggiungono, analogamente alle configurazioni SELF12 e SELF36, lo storico dei consumi dell’anno precedente, ottenendo la seguente struttura:

- Feature Descrittive:
 - o 12 feature dei consumi dei mesi precedenti
 - o anno target

- Feature Target:
 - o 12 feature dei consumi dei mesi successivi al target

3.1 Caratteristiche dei dataset

I dati considerati fanno riferimento ai consumi dei clienti con cadenza mensile dal 2010 al 2019 della rete elettrica di seguito denominata “rete test” e della rete di seguito denominata “rete reale MT” Attraverso il tool QGIS sono

state estratte le coordinate geografiche dei clienti dai dati inizialmente rappresentati tramite shapefile, e sono stati implementati specifici script Python per la selezione di campi a partire dai dati inizialmente rappresentati attraverso fogli excel (relativi ai clienti, misurazioni e agli identificativi delle cabine a cui sono associati i clienti, ecc.).

La fusione di questi in un unico file ha portato alle feature riportate nella seguente Tabella:

Feature	Descrizione
cliente	Identificativo cliente
data	Anno e mese della misurazione
latitudine	Latitudine del nodo a cui è associato il cliente
longitudine	Longitudine del nodo a cui è associato il cliente
energia_fascia_01	Consumo nella prima fascia oraria
energia_fascia_02	Consumo nella seconda fascia oraria
energia_fascia_03	Consumo nella terza fascia oraria
energia_totale	Somma del consumo delle tre fasce
picco_fascia_01	Massima misurazione di potenza nella prima fascia oraria
picco_fascia_02	Massima misurazione di potenza nella seconda fascia oraria
picco_fascia_03	Massima misurazione di potenza nella terza fascia oraria

Tabella 8 Feature estratte dai dataset

3.2 Setting sperimentale

La valutazione è stata svolta basandosi su una K-fold Cross-Validation specifica per serie temporali con k=8.

A differenza della K-fold Cross-Validation tradizionale, in questo caso il training set è sempre costruito utilizzando tutte le osservazioni temporalmente precedenti al testing set considerato.

La struttura delle configurazioni definite ha permesso di effettuare previsioni solo a partire dall'anno 2012, poiché per l'anno 2011 sarebbero stati necessari i dati relativi al 2010 con il relativo storico (anno 2009).

Per ogni fold di validazione, i clienti aventi più di 1/3 delle osservazioni mancanti sono stati rimossi. Questo accade principalmente per la presenza di clienti che hanno stipulato il contratto in un determinato anno ricadente nell'intervallo 2010-2019 considerato (i consumi degli anni precedenti a questo sono pari a 0).

Come misura di valutazione è stato considerato il Relative Squared Error (RSE), dato dal rapporto tra l'errore quadratico totale dei valori predetti e l'errore quadratico di un modello che utilizza la media come predittore.

$$RSE = \frac{\sum_t [r^t - \hat{r}^t]^2}{\sum_t [r^t - \bar{r}]^2}$$

dove:

- r^t è il valore reale
- \hat{r}^t è il valore predetto
- \bar{r} è il valore medio

Se l’RSE è vicino a 1 allora le predizioni del modello hanno la medesima accuratezza di un modello banale basato sulla media; un RSE pari a 0 rappresenta invece un modello con l’adattamento ottimale.

3.3 Esperimenti Rete test

Prima di applicare algoritmi di machine learning, i dati sono stati sottoposti ad una serie di operazioni di pre-processing. In primis, sono state rimosse eventuali misurazioni duplicate (circa 2.000) e quelle il cui identificativo del cliente era sconosciuto. Durante il processo di fusione tra le diverse sorgenti, è stata inoltre osservata l’assenza di alcune corrispondenze tra i codici identificativi dei clienti e le rispettive coordinate geografiche, dovuta all’inesattezza di alcuni codici composti da 15 caratteri alfanumerici piuttosto che 14. Ogni codice cliente è generalmente composto dalla stringa “POD” seguita da 11 cifre. In alcuni casi, tuttavia, nella quarta posizione della stringa era presente un carattere alfabetico che è stato dunque rimosso. Questa operazione ha permesso di recuperare parzialmente le corrispondenze tra clienti e coordinate, mentre le misurazioni rimanenti sono state rimosse.

Partendo dal dataset così ottenuto, sono state selezionate le seguenti feature: *cliente*, *data*, *latitudine*, *longitudine*, *energia_totale*, ottenendo 19080 misurazioni relative a 159 clienti.

Di seguito vengono illustrati i modelli di machine learning considerati e i valori prefissati dei loro parametri, prendendo come riferimento la libreria Scikit-learn di Python. Si dettano inoltre le diverse varianti considerate, variando alcuni dei suddetti parametri.

LinearRegression:

- *fit_intercept*: true [se True stima l’intercetta]

KNeighborsRegressor:

- *metric*: minkowski [metrica utilizzata per calcolare la distanza tra le osservazioni]
- *n_neighbors*: 5 [numero di vicini]
- *p*: 2 [esponente della distanza di Minkowski, se $p=1$ equivale alla distanza di Manhattan, se $p=2$ equivale alla distanza Euclidea]
- *weights*: ‘uniform’ [funzione di peso utilizzata nella predizione. Utilizzando ‘uniform’ indichiamo che tutti i punti di ogni vicinato incidono allo stesso modo nella predizione]

Sono state utilizzate diverse configurazioni di KNeighborsRegressor che differiscono nella scelta del parametro del numero di vicini, $n_neighbors \in \{1, 3, 5\}$.

MLPRegressor:

- *activation*: ‘relu’ [funzione di attivazione definita come la parte positiva del suo argomento: $\max(0, x)$]
- *batch_size*: ‘auto’ [dimensione dei minibatch utilizzati per l’ottimizzazione stocastica. Con ‘auto’ calcoliamo questa dimensione come $\min(200, n_samples)$]
- *hidden_layer_sizes*: [100,] [l’i-esimo elemento rappresenta il numero di neuroni dell’i-esimo strato nascosto]

- *learning_rate*: 'adaptive'. [tasso di apprendimento. Con 'adaptive' si mantiene il tasso di apprendimento costante finché l'errore di training continua a diminuire, altrimenti decresce]
- *max_iter*: 3000 [massimo numero di iterazioni]
- *solver*: 'adam' [ottimizzatore basato sulla discesa stocastica del gradiente]

Sono state valutate due diverse configurazioni di MLPRegressor che si differenziano nella scelta del numero di neuroni dello strato nascosto. Per la prima configurazione viene utilizzato il valore di default pari a 100 e per la seconda viene impostato a 10 seguendo l'euristica per la quale un numero accettabile di neuroni è dato da $2/3$ del numero di feature (considerando la configurazione SELF12, avente il minor numero di feature).

DecisionTreeRegressor:

- *ccp_alpha*: 0.2 [parametro di complessità usato per il Minimal Cost-Complexity Pruning]
- *criterion*: mse [funzione utilizzata per valutare la qualità dello split]
- *min_samples_leaf*: 1 [numero minimo di esempi richiesto per determinare un nodo foglia]
- *min_samples_split*: 2 [numero minimo di esempi richiesto per splittare un nodo interno]
- *splitter*: 'best' [strategia utilizzata per scegliere lo split migliore ad ogni nodo]

Per DecisionTreeRegressor sono state definite tre configurazioni, basate sul parametro di pruning $ccp_{\alpha} \in \{0.2, 0.5, 1\}$, utile per ridurre fenomeni di overfitting.

RandomForestRegressor:

- *n_estimators*: 100 [numero di alberi della foresta]
- *ccp_alpha*: 0.0 [parametro di complessità usato per il Minimal Cost-Complexity Pruning]
- *criterion*: mse [funzione utilizzata per valutare la qualità dello split]
- *min_samples_leaf*: 1 [numero minimo di esempi richiesto per determinare un nodo foglia]
- *min_samples_split*: 2 [numero minimo di esempi richiesto per splittare un nodo interno]

I risultati ottenuti saranno di seguito presentati sottoforma di istogrammi, utilizzando la seguente notazione per distinguere le diverse configurazioni che colgono gli aspetti spazio-temporali:

- **"No_temp"**: configurazione base senza alcuna informazione di carattere temporale;
- **"normalization_year"**: configurazione che sfrutta la tecnica di normalizzazione degli istanti temporali;
- **"cyclical_month"**: configurazione che sfrutta la tecnica che coglie la ciclicità dei mesi;
- **"both_temporal"**: configurazione che sfrutta entrambe le tecniche per cogliere l'autocorrelazione temporale;
- **"No_spatial"**: configurazione base senza alcuna informazione di carattere spaziale;
- **"LISA"**: configurazione che coglie l'autocorrelazione spaziale mediante LISA; il parametro maxDist è stato impostato a 0.3km, calcolata per le 12 feature relative ai consumi dello storico;
- **"PCNM"**: configurazione che coglie l'autocorrelazione spaziale attraverso l'applicazione della PCNM, utilizzando una *threshold* pari a 0.3 km ed estraendo 15 componenti principali dalla PCoA.

3.3.1 Valutazione autocorrelazione temporale

Si analizzano di seguito i risultati ottenuti dai vari metodi di regressione per le configurazioni SELF12, SELF36 e multi-step, valutando per ciascuna di esse l'effetto della presenza delle informazioni che permettono di catturare l'autocorrelazione temporale.

In Figura 14 sono illustrati i risultati per la configurazione SELF12, in termini di RSE medio rispetto all'intero periodo di analisi. Notiamo che i metodi con cui si ottengono risultati migliori sono MLP con 10 neuroni nello strato nascosto, Linear Regression e KNN con K=5. Inoltre, le tecniche per cogliere l'autocorrelazione temporale non portano ad un miglioramento significativo della predizione.

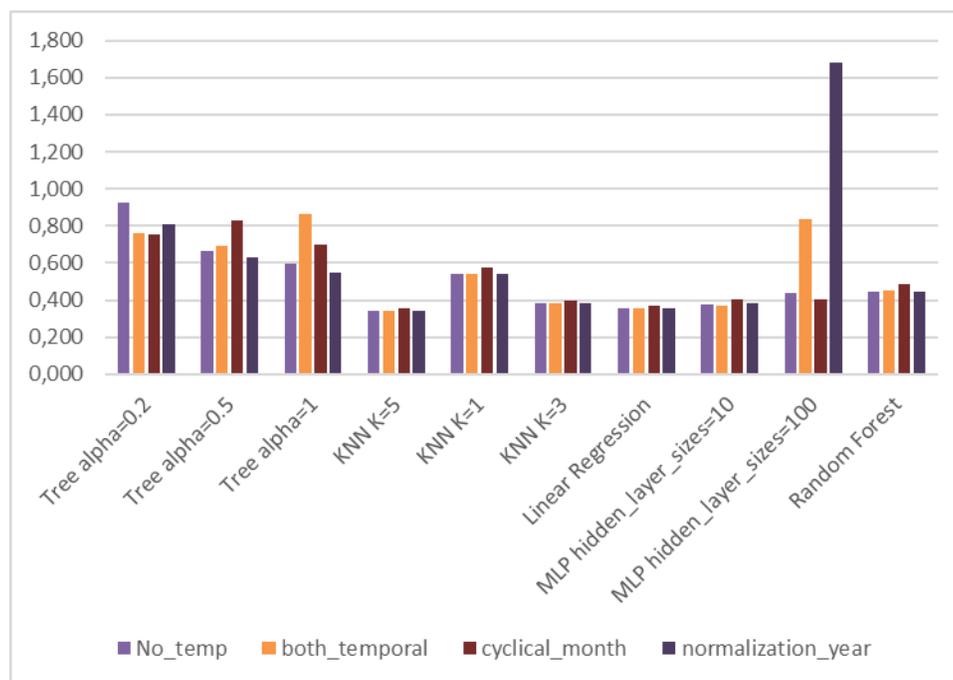


Figura 14 Rete TEST BT, RSE Medio SELF12, Autocorrelazione temporale

Per la configurazione SELF36 Figura 15 si osservano risultati analoghi a quelli ottenuti con SELF12. Si osserva, tuttavia, un calo di prestazioni per gli alberi di regressione rispetto alla configurazione SELF12.

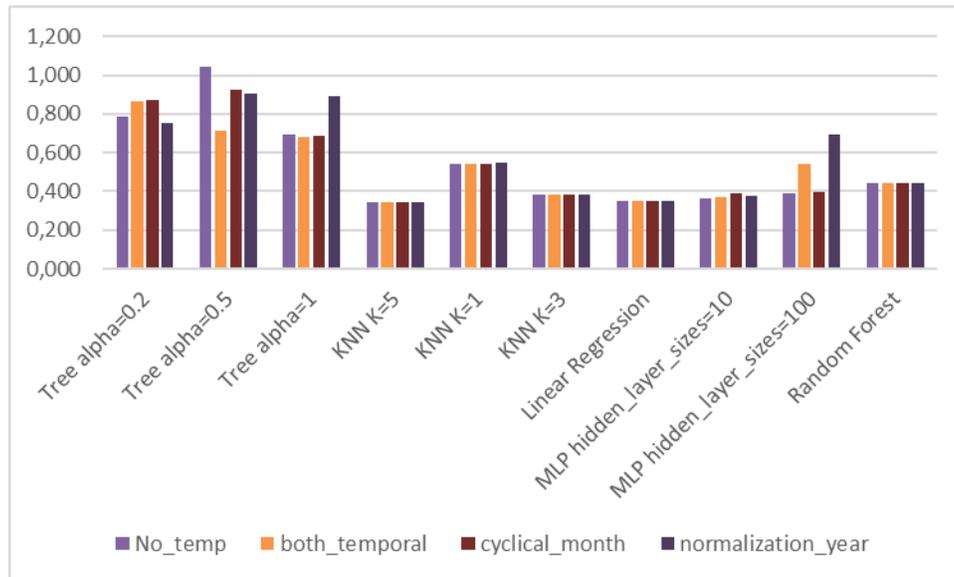


Figura 15 Rete TEST BT, RSE Medio SELF36, Autocorrelazione temporale

Per la configurazione multi-step Figura 16 si ottengono dei buoni risultati con KNN (K=5) e Random Forest. Si può osservare come KNN degradi le sue prestazioni man mano che l'iperparametro K decresce. Gli alberi di regressione sono risultati poco performanti, pur avendo valutato diversi valori per il parametro di pruning $ccp_alpha_$.

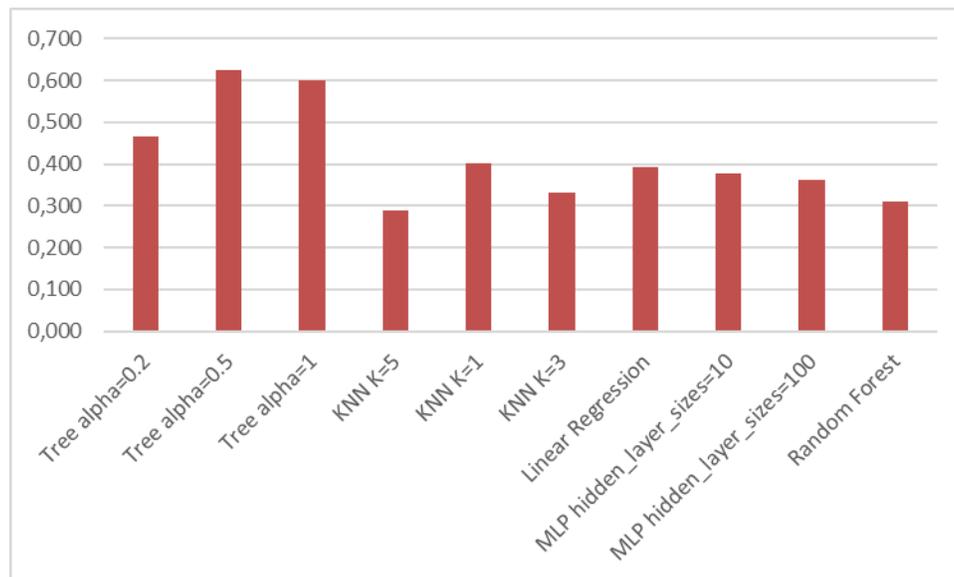


Figura 16 Rete TEST BT, RSE Medio multi-step, Autocorrelazione temporale

I risultati ottenuti sono stati sottoposti ad un test statistico, ossia il Friedman Nemenyi test, in grado di evidenziare differenze in termini di significatività statistica tra varie configurazioni.

In Figura 17 Figura 18 Figura 19 si riportano graficamente i risultati del test, confrontando i diversi regressori. Regressori che ricadono nel segmento definito dalla critical distance sono ritenuti statisticamente equivalenti in termini di accuratezza predittiva.

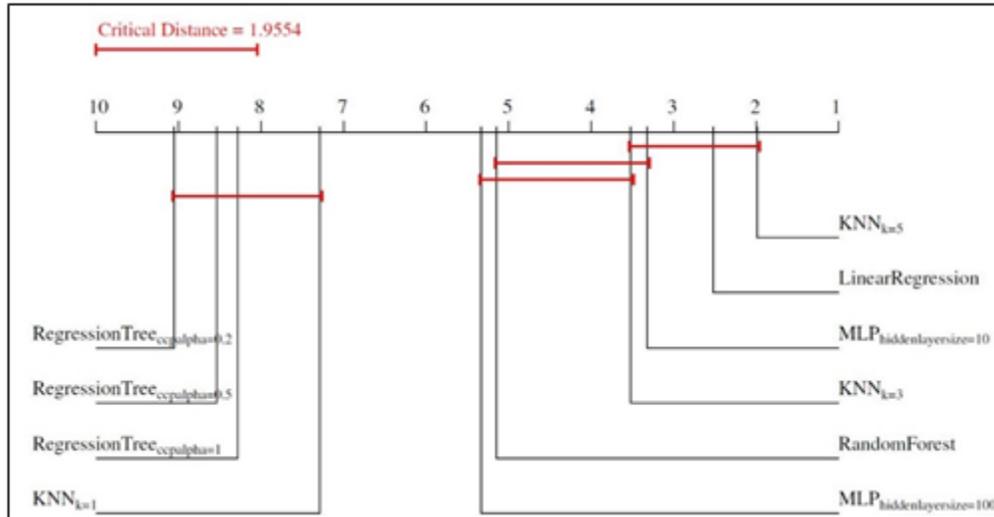


Figura 17 Rete TEST BT, Test Friedman-Nemenyi Self12

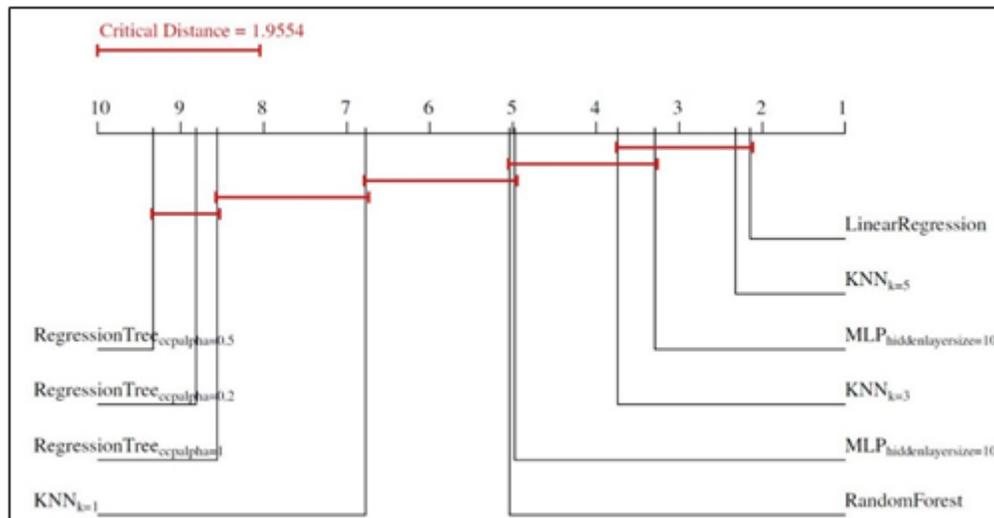


Figura 18 Rete TEST BT, Test Friedman-Nemenyi Self36

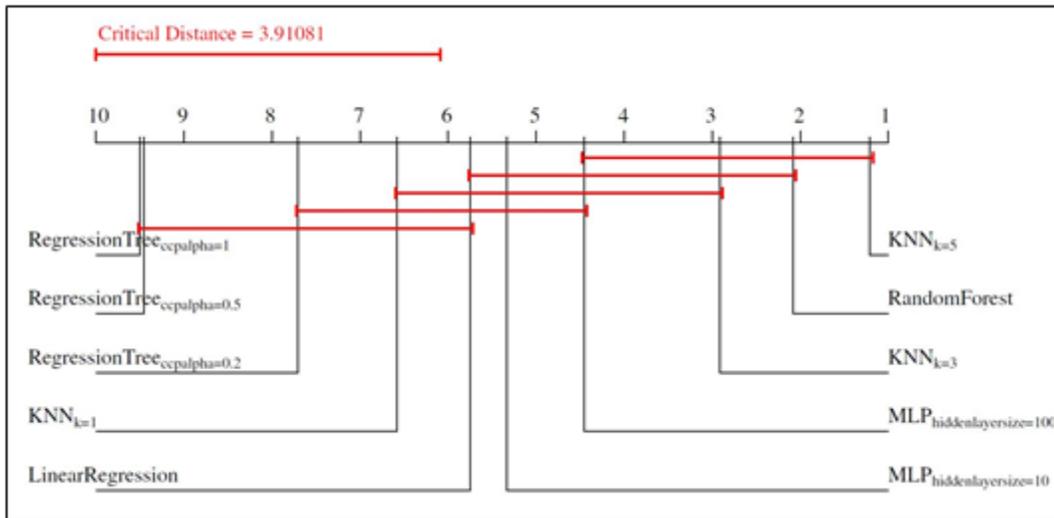


Figura 19 Rete TEST BT, Test Friedman-Nemenyi multi-step

Infine, in Figura 20 si riportano graficamente i risultati del medesimo test, confrontando le diverse strategie per cogliere l'autocorrelazione temporale. Dalla figura, si può notare che Multi-Step, catturando in maniera implicita il tempo, permette di ottenere una predizione più accurata rispetto alle configurazioni SELF in cui l'autocorrelazione temporale è modellata attraverso la costruzione di feature aggiuntive.

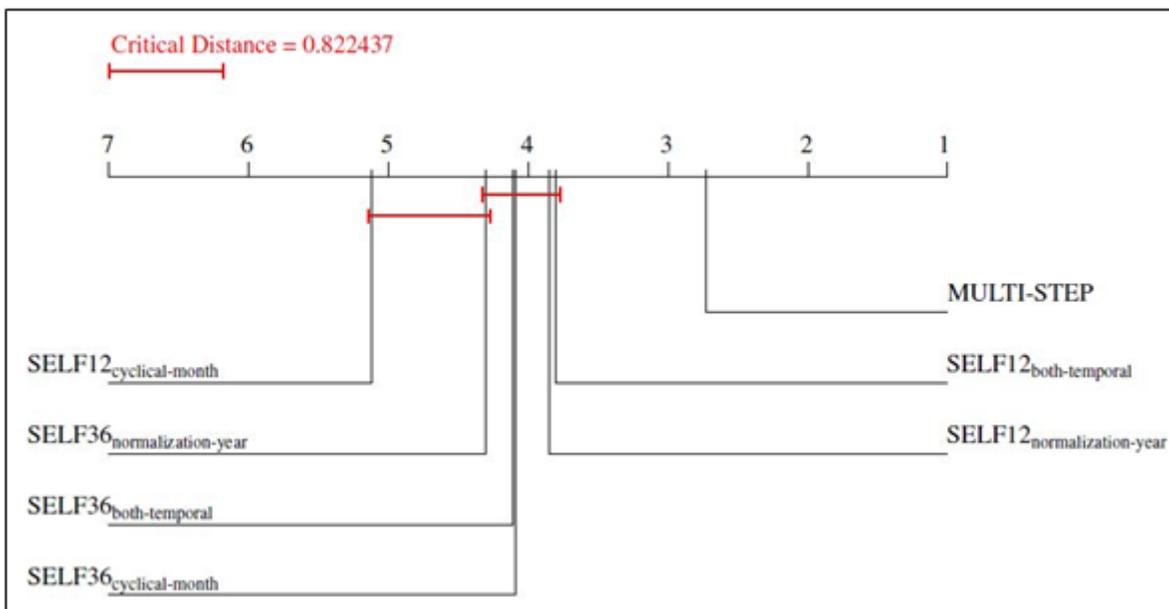


Figura 20 Rete TEST BT, Test Friedman-Nemenyi, confronto configurazioni autocorrelazione temporale

Si riportano di seguito alcuni grafici aggiuntivi (Figura 21 Figura 22) relativi alla configurazione multi-step che permettono di confrontare i i valori reali con quelli predetti relativi all'anno 2019, allo scopo di evidenziare se i vari metodi di regressione riescono a cogliere il trend dei consumi. Nelle figure, si utilizza la seguente notazione:

- **RegressionTree_1:** *RegressionTree (ccp_alpha=0.2)*
- **RegressionTree_2:** *RegressionTree (ccp_alpha=0.5)*
- **RegressionTree_3:** *RegressionTree (ccp_alpha=1)*
- **MLPRegressor_1:** *MLPRegressor (hidden_layer_size(100))*
- **MLPRegressor_2:** *MLPRegressor (hidden_layer_size(10))*
- **KNN_k=1:** *KNN (n_neighbors = 1)*
- **KNN_k=3:** *KNN (n_neighbors = 3)*
- **KNN_k=5:** *KNN (n_neighbors = 5)*

In particolare, consideriamo due clienti di riferimento:

- C1 - con un aumento dei consumi nei mesi estivi e un notevole calo nel mese di ottobre.
- C2 - con un andamento che decresce nei mesi estivi e poi risale nel periodo invernale.

Dai risultati relativi al cliente C1 Figura 21 notiamo che tutti i metodi sono riusciti a cogliere i picchi dei mesi estivi; tuttavia, nessuno ha predetto in maniera accurata il consumo del mese di ottobre e il successivo aumento del mese di novembre, ad eccezione di *RegressionTree_1* e *KNN_k=1*. Osservando i risultati relativi al cliente C2 Figura 22, si può notare che quasi tutti i metodi riescono ad approssimare i valori reali. Tuttavia, *RegressionTree_1* è l'unico che coglie il picco del mese di settembre. Inoltre, *LinearRegression* e *RandomForest* non predicano in maniera accurata il mese di agosto, ma riescono a migliorare la predizione per il mese di settembre rispetto agli altri metodi. Infine, notiamo che le configurazioni di MLP degli ultimi 3 mesi risultano essere migliori di quelle dei mesi iniziali.

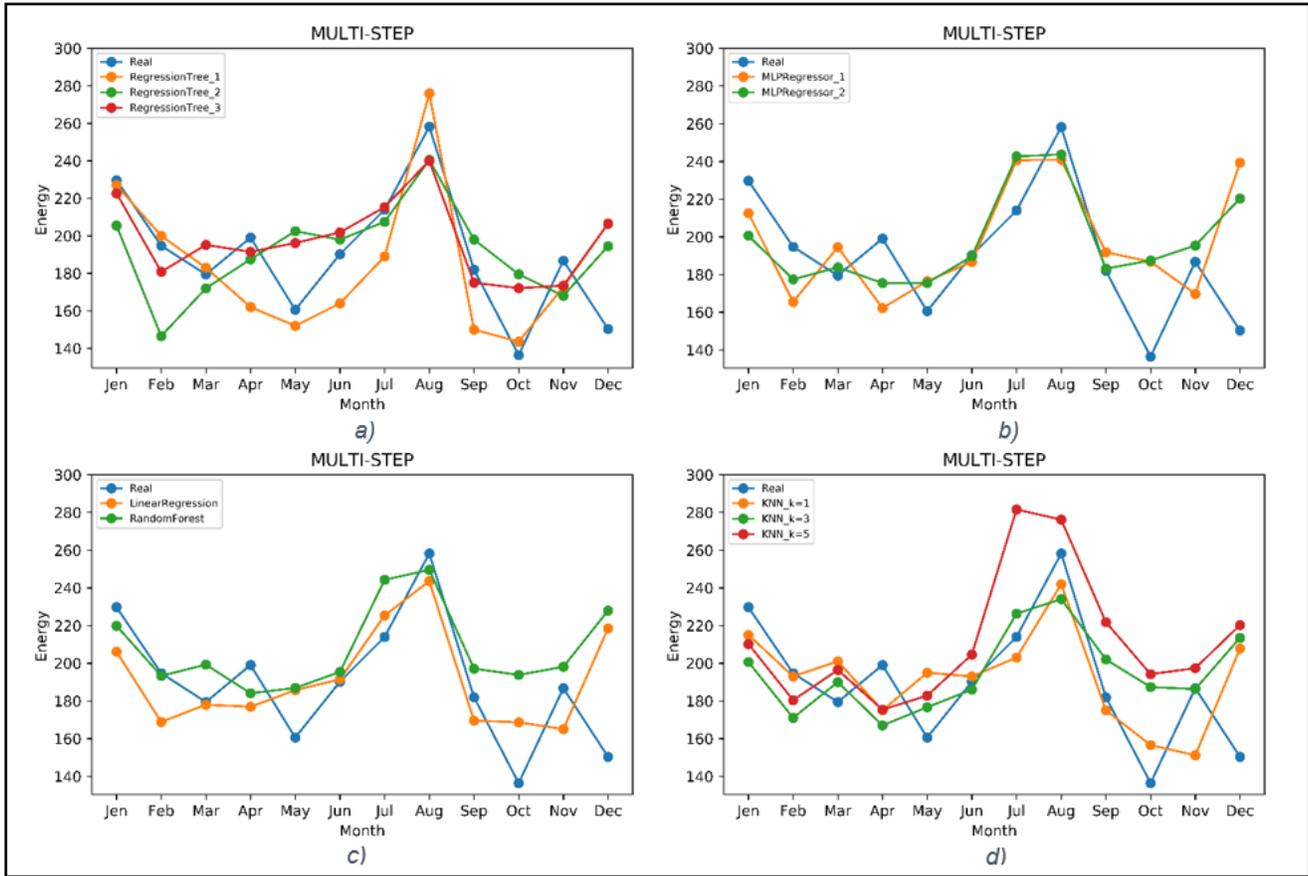


Figura 21 Rete TEST BT, valori reali-predetti multi-step cliente C1

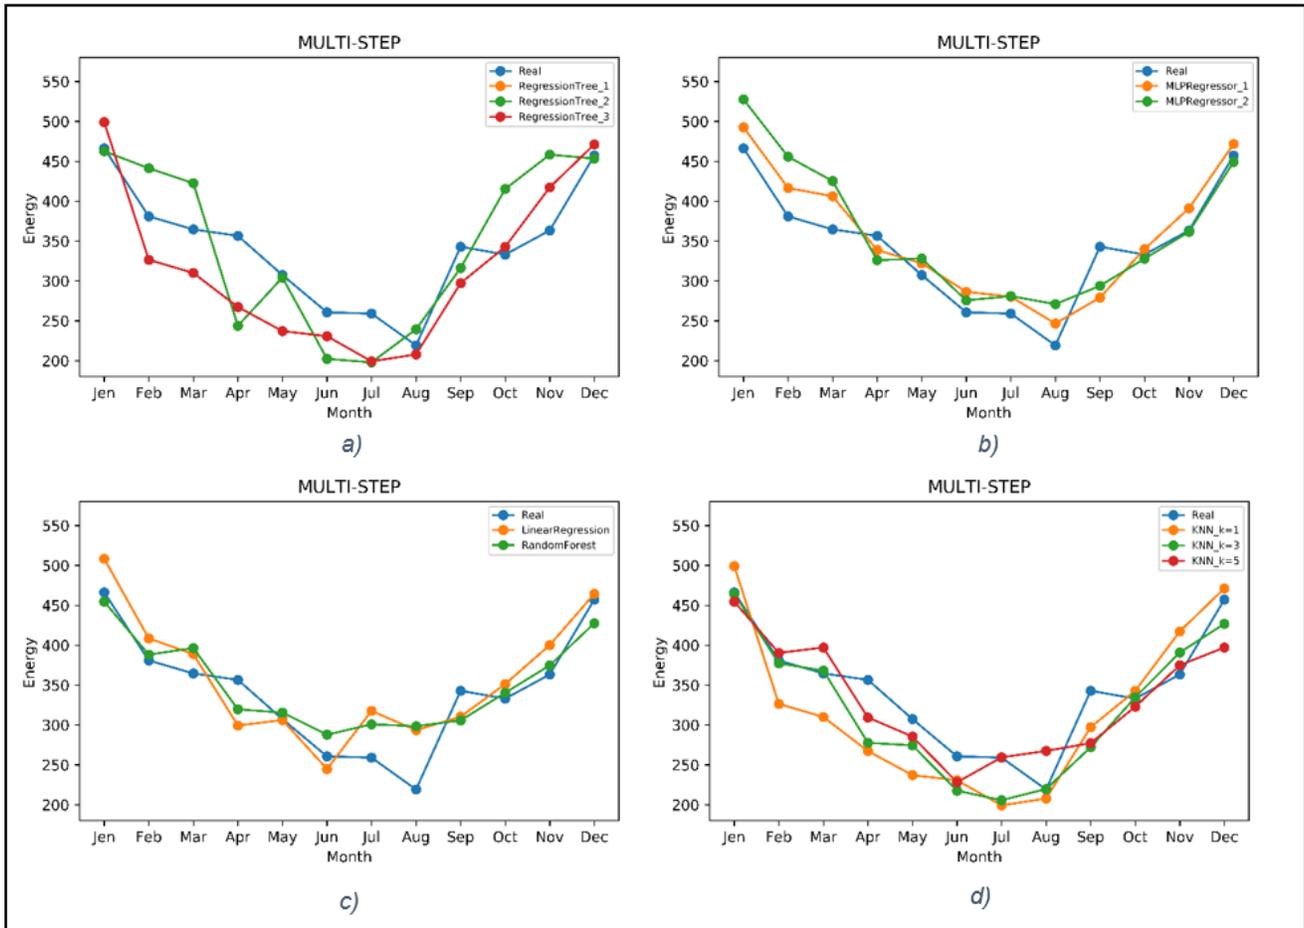


Figura 22 Rete TEST BT, valori reali-predetti multi-step cliente C2

3.3.2 Valutazione autocorrelazione spaziale

Si analizza di seguito il contributo derivante da metodi per cogliere l'autocorrelazione spaziale per le diverse configurazioni definite. Per SELF12 i metodi di regressione con cui si ottiene una predizione più accurata risultano essere KNeighbors con $k=5$, LinearRegression e MLP con $hidden_layer_sizes=10$ (Figura 23). Anche in questo caso, l'autocorrelazione spaziale non porta un contributo elevato, ad eccezione dei metodi basati su alberi di regressione. Questo può essere dovuto al fatto che il dataset è relativo ad una area geografica di ampiezza limitata.

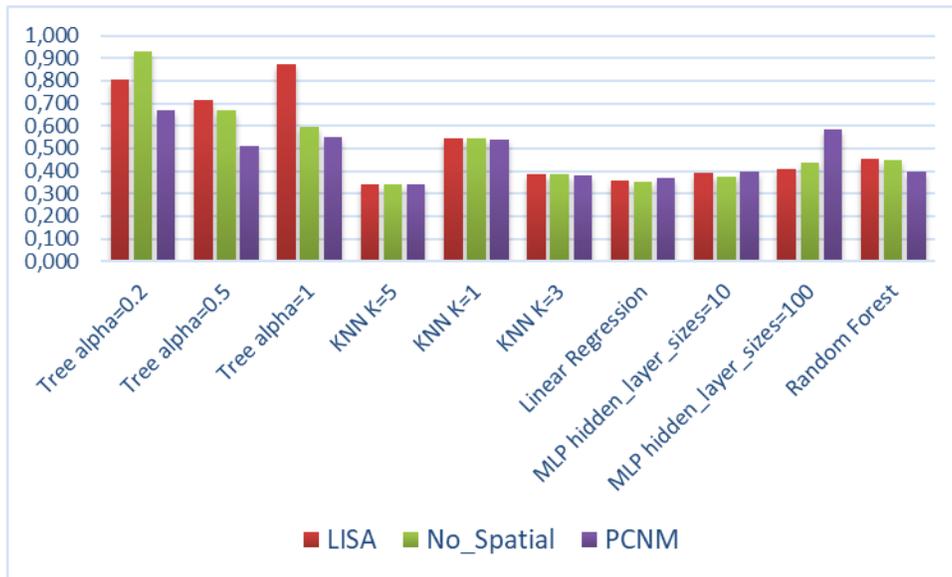


Figura 23 Rete TEST BT, RSE Medio SELF12, Autocorrelazione spaziale

Per la configurazione SELF36 si osservano risultati analoghi a quelli ottenuti con SELF12 (Figura 24). In questo caso, si verifica un leggero miglioramento nella predizione per tutti i metodi e in particolare per MLP con *hidden_layer_size=100*, raggiungendo un netto miglioramento rispetto a SELF12 con la configurazione No_Spatial e con PCNM.

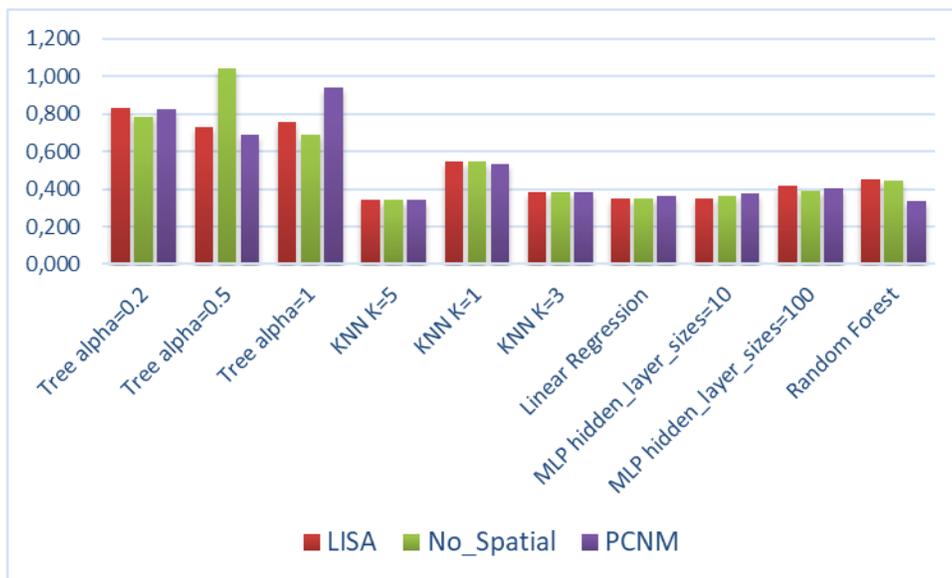


Figura 24 Rete TEST BT, RSE Medio SELF36, Autocorrelazione

Per la configurazione multi-step (Figura 25) si ottengono i migliori risultati con Random Forest e K-Neighbors. Quest'ultimo si comporta allo stesso modo per tutte le tecniche utilizzate (PCNM, LISA, No_Spatial). D'altra parte,

notiamo un miglioramento nella predizione con l'applicazione della PCNM utilizzando Random Forest. Inoltre, osserviamo che MLP con un numero di neuroni pari a 10 ha prodotto risultati analoghi a Random Forest utilizzando le feature ottenute dall'applicazione di LISA.

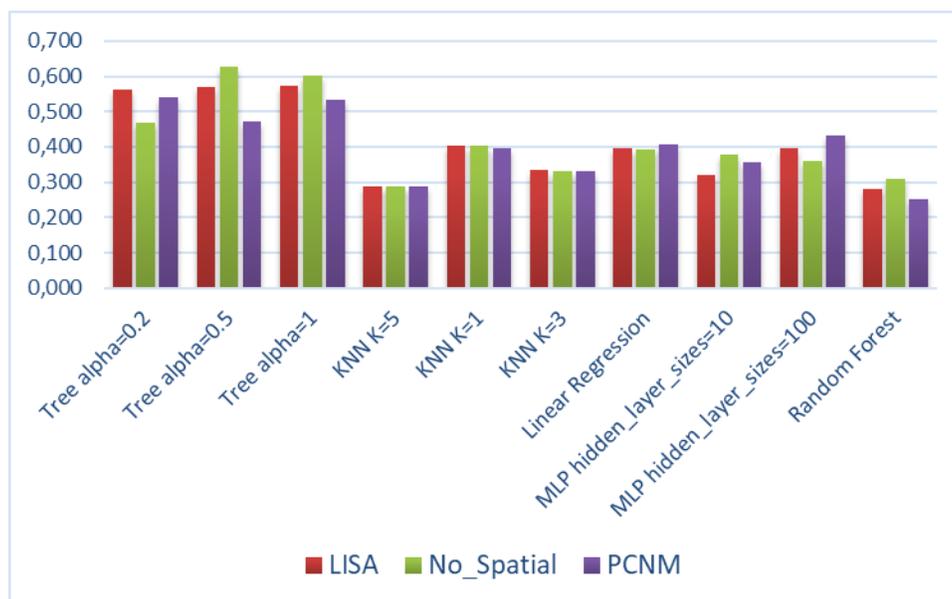


Figura 25 Rete TEST BT, RSE Medio multi-step, Autocorrelazione spaziale

In Figura 26 si riporta graficamente il risultato del test di Friedman-Nemenyi, in cui si confrontano le varie configurazioni relative alla modellazione dell'autocorrelazione spaziale e temporale. Dal risultato, è possibile concludere che le migliori predizioni si ottengono quando si utilizzano simultaneamente le configurazioni multi-step, per cogliere l'autocorrelazione temporale, e PCNM, per cogliere l'autocorrelazione spaziale.

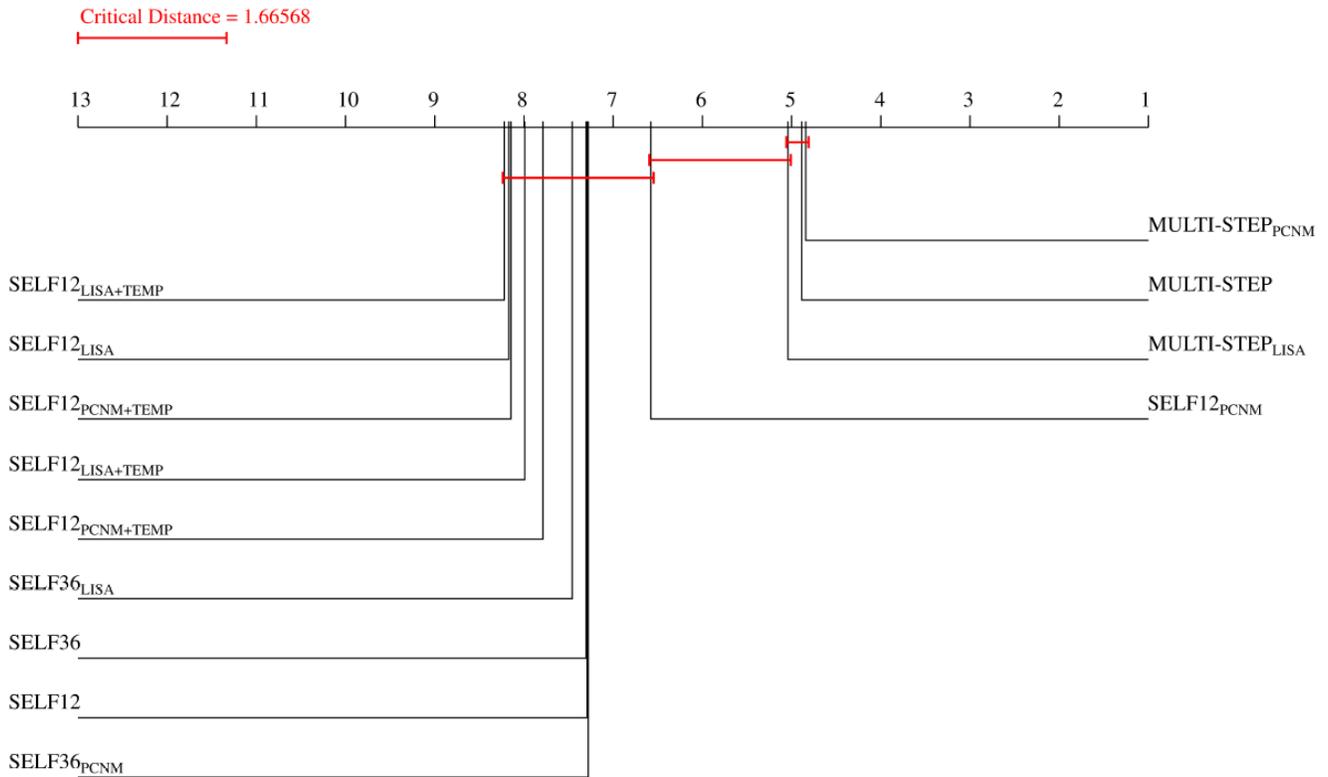


Figura 26 Rete TEST BT, Test Friedman-Nemenyi, confronto configurazioni autocorrelazione spaziale e temporale

Di seguito si mostrano alcuni grafici aggiuntivi che mostrano valori reali-predetti di un cliente campione dal 2014 al 2019 per la configurazione multi-step con Random Forest (Figura 27). In questo caso, si evidenzia che il contributo della modellazione dell'autocorrelazione spaziale è più prezioso quando i dati sono pochi, ovvero nei primi anni della cross-validation; quando il numero di dati aumenta il contributo decresce.

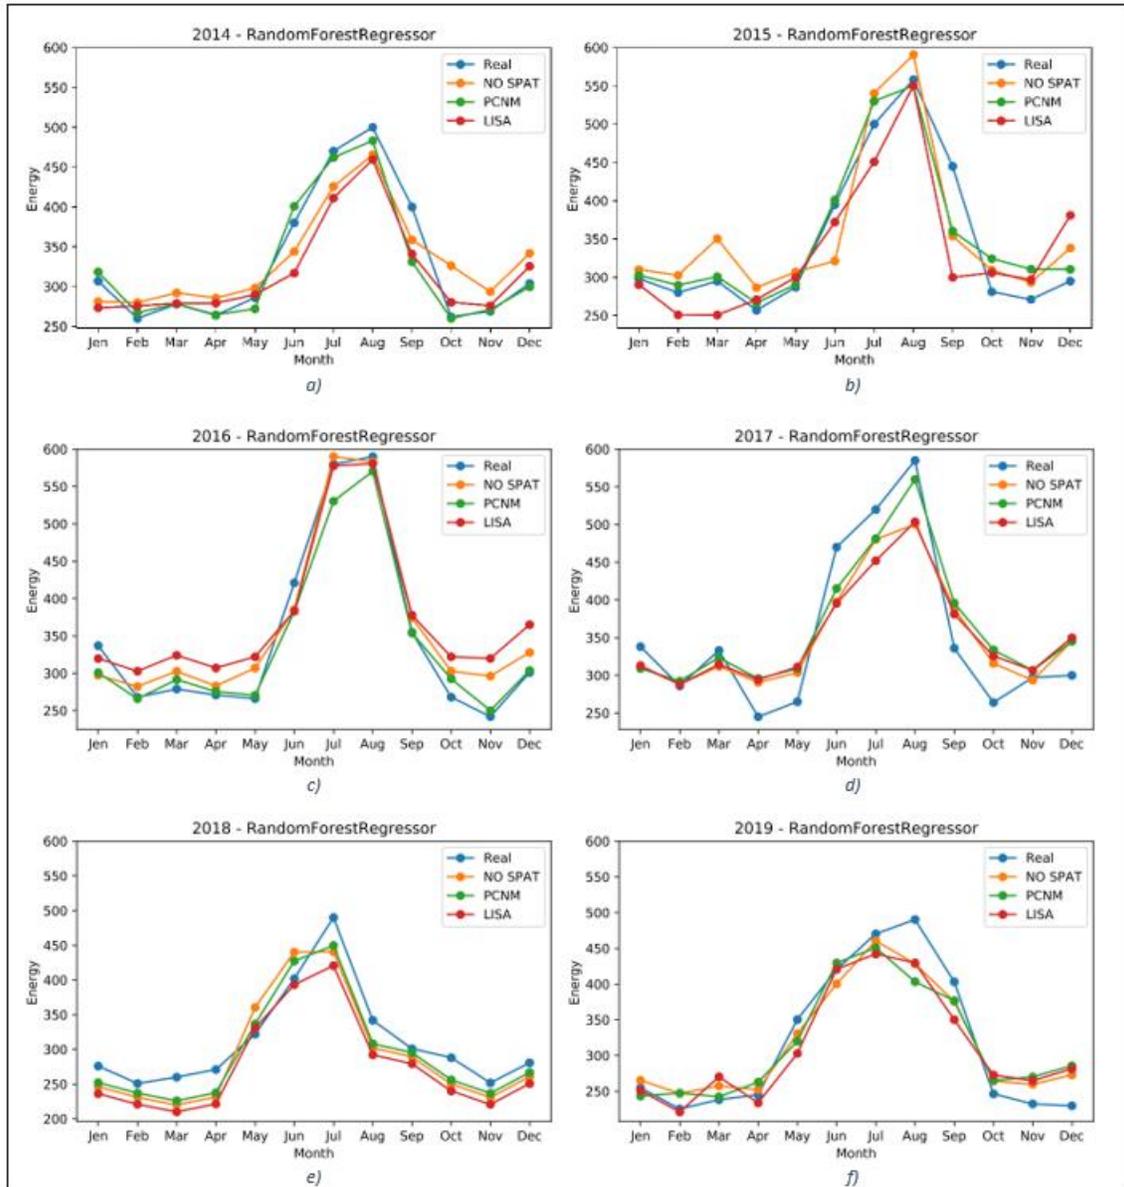


Figura 27 Rete TEST BT, valori reali-predetti multi-step & autocorrelazione spaziale

3.4 Esperimenti Rete MT reale e cabine secondarie

Analogamente alla rete test, per la rete della linea MT reale i dati sono stati sottoposti a pre-processing, portando ad un totale di 453.480 misurazioni, relativi a 3.779 clienti. Inoltre, sono stati individuati e alcuni valori outlier, ossia al di fuori dell'intervallo $[\mu-5\sigma, \mu+5\sigma]$, per le feature *energia_fascia_01*, *energia_fascia_02*, *energia_fascia_03*, *energia_totale*.

Tali valori sono stati sostituiti con dei valori stimati nel seguente modo: valori anomali individuati nelle singole fasce orarie sono stati sostituiti con il precedente (temporalmente) valore non anomalo, mentre *energia_totale* è stata ricalcolata come somma dei valori delle tre fasce.

Anche in questo caso, sono state considerate le feature scelte nell'esperimento precedente (*cliente, data, latitudine, longitudine, energia_totale*) in quanto l'obiettivo è il medesimo, ovvero predire un unico valore di consumo per ogni cliente.

A seguito dei risultati ottenuti dall'esperimento sulla rete test, si è scelto di eseguire gli esperimenti utilizzando la configurazione più promettente, ossia multi-step e multi-step + PCNM. I metodi di regressione considerati sono Random Forest, K-Nearest Neighbors con $k=5$ e Linear Regression. È stata utilizzata una *threshold* pari a 150 metri per il metodo PCNM e sono state estratte le prime 15 componenti principali dalla PCoA.

In Figura 28 e Figura 29 sono illustrati i risultati in termini di RSE medio rispetto all'intero periodo di analisi. Notiamo che tutti i metodi considerati ottengono un errore di predizione molto basso. In particolare, Linear Regression e Random Forest con l'applicazione della PCNM producono i migliori risultati. Inoltre, si evidenzia che all'aumentare del numero di campioni l'errore decresce. Questo supporta ulteriormente l'ipotesi che l'RSE più basso qui ottenuto, rispetto agli esperimenti condotti sulla rete test, sono dovuti ad una più ampia disponibilità di esempi di apprendimento.

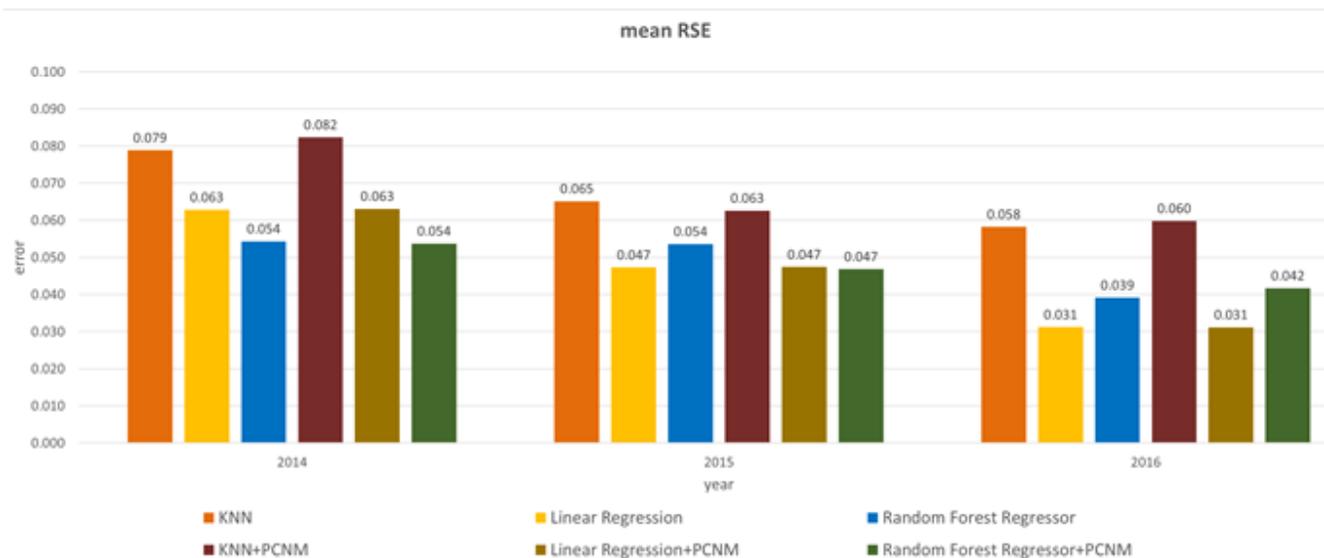


Figura 28 rete MT reale, Multi-Step/Multi-Step + PCNM (2014-2015-2016)

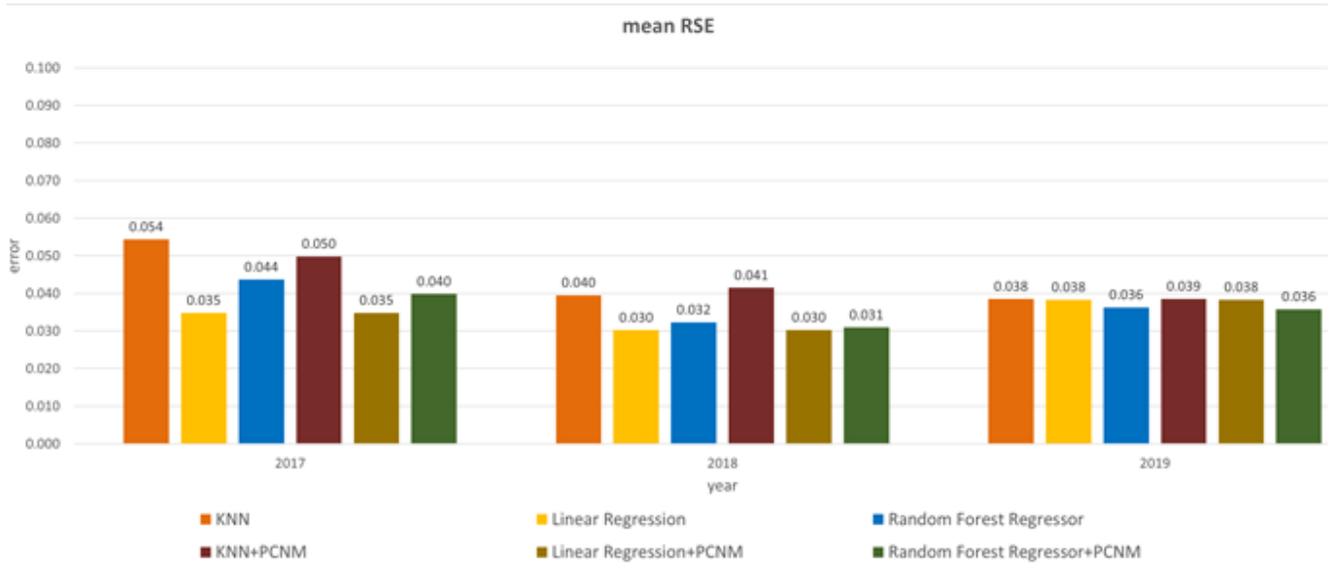


Figura 29 rete MT reale, Multi-Step/Multi-Step + PCNM (2017-2018-2019)

In Figura 30 e Figura 31 si riportano, infine, alcuni grafici che mostrano l'andamento dei valori reali-predetti di un cliente campione per l'intero periodo di analisi con il metodo RandomForest.

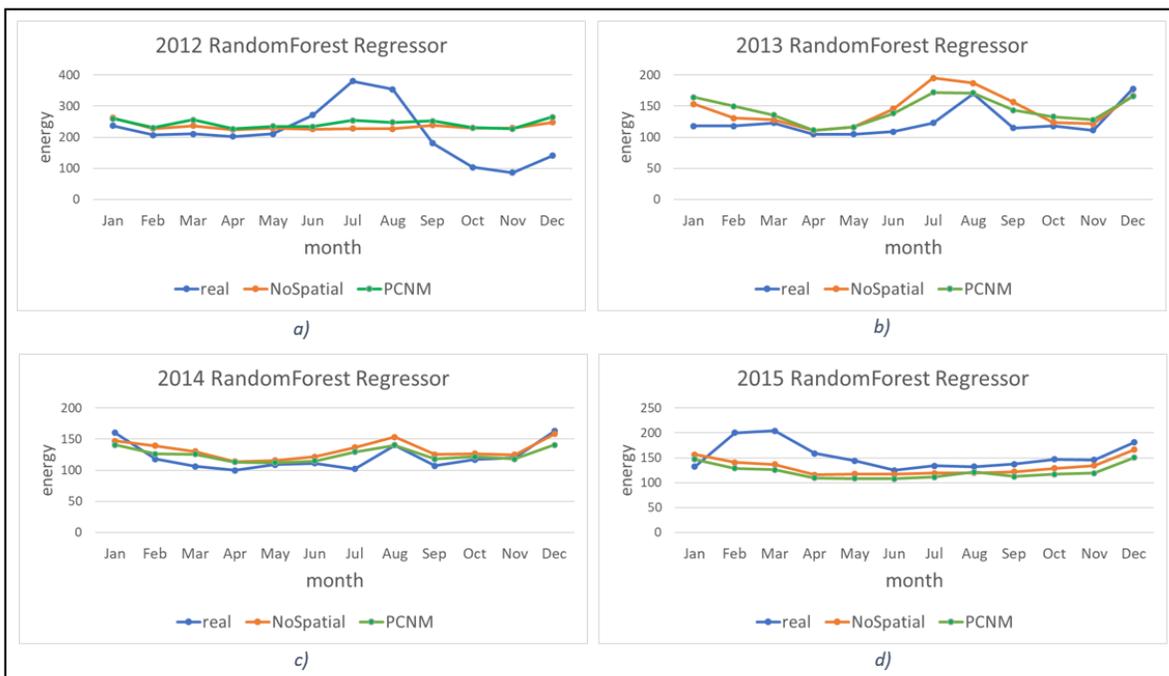


Figura 30 rete MT reale, Valori reali-predetti Multi-Step/Multi-Step + autocorrelazione spaziale

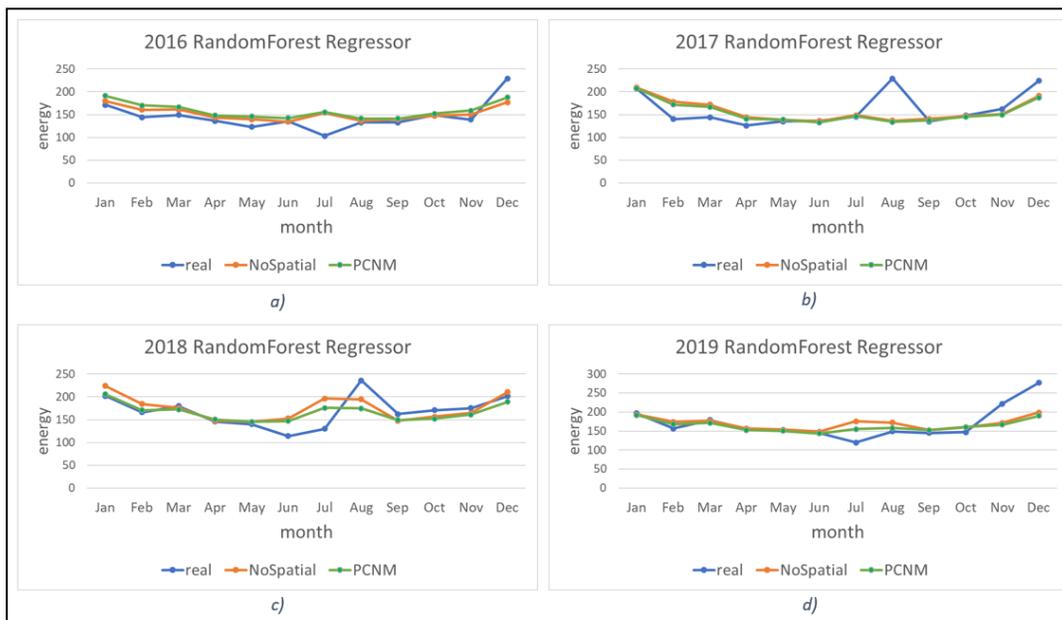


Figura 31 rete MT reale, Valori reali-predetti Multi-Step/Multi-Step + autocorrelazione spaziale

3.5 Applicazione di Tecniche di Transfer Learning

E' stata infine valutata la possibilità di adottare tecniche di transfer learning per supportare la predizione del carico. Tali tecniche hanno come obiettivo l'apprendimento di un modello a partire da un contesto, e la sua adozione a fini predittivi in altri contesti.

E' bene notare che i risultati ottenuti sulla rete MT reale sono apparsi molto migliori in termini di accuratezza, rispetto a quelli ottenuti sulla rete test. Si è deciso dunque di investigare la possibilità di sfruttare il modello appreso su rete MT reale per migliorare la predizione su rete test.

La combinazione tra i modelli appresi è stata eseguita attraverso una tecnica basata sul meta-learning e, in particolare, sullo stacked generalization, che apprende un ulteriore modello che punta a combinare i contributi dei modelli di partenza. I modelli considerati per combinare l'output dei modelli di partenza sono stati 3, ossia linear regression, MLP con funzione di attivazione ReLU e MLP con funzione di attivazione Sigmoid. I risultati ottenuti nella predizione della rete test sono riportati in Tabella 9. Si riportano, inoltre, in Tabella 10 i risultati ottenuti nella direzione opposta, ossia nella predizione sulla rete MT reale sfruttando la rete test.

Regressor	RSE
Linear Regression	0,1272

MLP (RELU)	0,1266
MLP (Sigmoid)	0,1263

Tabella 9 Risultati ottenuti tramite transfer learning rete MT reale->rete test

Regressor	RSE
Linear Regression	0,8490
MLP (RELU)	0,7549
MLP (Sigmoid)	0,9066

Tabella 10 Risultati ottenuti tramite transfer learning rete test -> rete MT reale

Dai risultati si può concludere che i dati relativi ad una rete costituita da molti clienti, come quella reale, possono essere sfruttati positivamente per migliorare le predizioni relative ad una rete più piccola, o di cui i dati a disposizione sono limitati. Infatti, i risultati ottenuti nella direzione rete MT reale->rete test risultano migliori di qualsiasi modello appreso solamente sulla rete test. Al contrario, l'utilizzo dei dati della rete test, più piccola, per la predizione dei consumi relativi alla rete MT reale, più grande, ha causato fenomeni di *negative transfer*.

4. CONCLUSIONI

Nell'AR 8.1a sono stati analizzati i risultati prodotti dall'ottimizzatore sia su rete di TEST BT, sia su rete reale MT, dimostrando l'efficacia dello stesso seppur ricevendo in input reti con configurazioni molto diverse tra loro. Si è evidenziato infatti come la rete di Test Bt richieda più interventi essendo stata scelta ad hoc in ottica ComESTo con uno scenario evolutivo futuro ricco di generazione distribuita, storage e comunità energetiche.

Si può apprezzare come l'ottimizzazione abbia un duplice risvolto positivo: da un lato riduce il KPI globale, dall'altro, seppur il KPI dovesse rimanere elevato, riduce drasticamente e in modo benefico il numero di occorrenze critiche che stresserebbero la rete.

D'altro canto, le tecniche di Machine Learning investigate per la predizione del consumo hanno mostrato risultati accurati, specie quando si sfruttano simultaneamente le caratteristiche spaziali e temporali dei dati a disposizione. Questo aspetto apre a numerose applicazioni future che possano beneficiare dell'azione combinata dei modelli predittivi e dell'ottimizzatore sviluppato. In particolare, si potrebbero utilizzare i modelli predittivi sviluppati per rendere l'ottimizzatore più consapevole non solo di scenari futuri in termini di storage e impianti di produzione, ma anche in termini di nuove esigenze di carico.