

Le tecnologie tradizionalmente utilizzate per il condizionamento estivo sono causa di notevoli sovraccarichi della rete elettrica di distribuzione con conseguente rischio di black-out elettrici. In particolare, il rischio è di dover aumentare significativamente la potenza installata senza un corrispondente aumento del consumo con il risultato di un costo dell'energia più alto.

In questo contesto, **la previsione del carico**, in un orizzonte temporale vario, **svolge un ruolo critico** per la gestione delle operazioni in ambito elettrico. Nelle reti elettriche del futuro una previsione accurata e robusta permetterebbe di ottenere un maggiore controllo e flessibilità rispetto alle reti odierne e si potrebbero limitare i problemi derivanti da picchi inattesi. In più, si potrebbero avere informazioni molto utili nell'acquisto e nello scheduling della produzione energetica. Inoltre una predizione accurata avrebbe un impatto notevole su tutte le operazioni di gestione, evitando ad esempio i sovraccarichi e permettendo un immagazzinamento più efficiente. Infine, **l'abilità di predire i comportamenti futuri degli utenti e le loro richieste è una parte necessaria dell'intelligenza richiesta dalle Smart Grids**, dove le tecnologie dell'informazione sono molto utilizzate. Un uso intenso della Generazione Distribuita presenta delle nuove sfide, come il bisogno di un "Intelligenza Distribuita" che permetta di gestire tutte le informazioni prodotte in luoghi diversi da sistemi differenti. Ovviamente uno studio in quest'ambito deve cominciare in scala più piccola, sulla scala degli edifici, studiando le prestazioni delle tecniche predittive consolidate, e solo successivamente conviene spostarsi in un ambito più ampio e complesso.

Descrizione delle attività svolte

Le attività svolte dal Politecnico di Torino, Dipartimento di Energetica, **in collaborazione con l'ENEA**, hanno riguardato lo sviluppo delle metodologie di modellazione predittiva dell'intero sistema edificio-climatizzazione, attraverso cui si intende cogliere l'ulteriore margine di efficienza ma anche garantire la robustezza del sistema nel suo insieme.

In particolare :

- è stata sviluppata una metodologia innovativa per la **previsione a breve termine** della richiesta energetica di un edificio complesso;
- è stata effettuata la **sperimentazione** su un edificio ENEA;

La Previsione a Breve Termine

Generalmente si parla di previsione a breve termine quando l'orizzonte temporale varia dall'ordine delle ore a quello di una settimana. I dati di carico energetico normalmente mostrano una o più periodicità che consentono di correlare il carico richiesto in certo momento al valore assunto nell'ora precedente ma anche a quello richiesto nello stesso orario della settimana precedente.

A seguito di una **campagna di monitoraggio condotta sull'edificio C59 del C.R. ENEA della Casaccia sono stati raccolti dati relativi a carico elettrico orario** , a grandezze climatiche di interesse e al numero di presenze nell'edificio. **Tali dati hanno consentito di correlare proprio il carico richiesto al numero di persone presenti (fig.1).**




Fig 1:	Relazione tra numero di persone nell'edificio e carico
(Sistemi di regolazione,	monitoraggio e controllo degli impianti di climatizzazione)

Sono stati quindi implementati dei modelli predittivi che ricostruiscono progressivamente nel tempo il profilo di utenza dell'edificio al fine di ottimizzarne la prestazione e qualificarli sulla base di dati sperimentali acquisiti.

Il modello Naive, considerato principalmente per la sua semplicità, **predice il segnale (carico elettrico)** in certo istante fornendo lo stesso valore osservato esattamente una settimana prima.

Il modello ARIMA di Box-Jenkins assume che il segnale futuro sia una funzione lineare delle osservazioni passate con l'aggiunta di un termine di errore (supposto a media nulla).
 Data la periodicità dei dati, è stata considerata **la variante "stagionale" dei modelli ARIMA, chiamata SARIMA**

Le reti neurali sono strumenti di modellazione non-lineare pensati per trovare la relazione ottimale tra ingressi e uscite osservati in un sistema durante una fase chiamati di 'addestramento'.

Le reti più usate sono le reti feed-forward come i perceptron multistrato (MLP) i cui pesi sono generalmente definiti usando il **noto algoritmo di backpropagation**

Il modello predittivo può utilizzare in ingresso solo i valori passati dell'uscita:

$$x_t = f(x_{t-1}, \dots, x_{t-n})$$

oppure ulteriori informazioni esterne
disponibili all'istante
per predire

$$x_t = f(x_{t-1}, \dots, x_{t-N}, I_t, \dots, I_{t-R})$$

In questo lavoro sono state scelte due tipologie di rete neurale: **percettroni multistrato** (MLP) e **reti neurali a base radiale** (RBF).

Sperimentazione dei modelli di previsione

I modelli selezionati, calibrati usando una parte dei dati disponibili, sono stati utilizzati per prevedere il carico orario sulla parte restante dei dati non usati in fase di calibrazione.

La parte di test è stata a sua volta suddivisa in due parti (T1 e T2) così da fornire un'informazione più granulare sul comportamento dei vari modelli.

Due criteri di errore sono stati usati per valutare i singoli modelli, il **MSE (Errore Quadratico Medio)** e il **MAE (Errore Assoluto Medio)**.

. In aggiunta abbiamo considerato anche l'errore assoluto massimo visto la sua importanza come discusso precedentemente.

Nella Tabella 1 mostriamo i risultati dei vari modelli, sia sull'insieme di training che su quelli di testing in cui vengono evidenziate le buone prestazioni dei modelli MLP. Il modello SARIMA mostra un errore massimo di testing ottimo per T1 e molto vicino all'ottimo (ottenuto dalla rete RBF) nel caso T2.

Modello	Training		Testing T1			Testing T2		
	MAE	StDE	MAE	StDE	Max	MAE	StDE	Min
Naive	2.45	14.97	2.11	7.61	7.11	2.28	6.4	8.16
SARIMA	1.14	4.34	1.89	5.52	7.84	1.42	2.77	4.79
ANN MLP best training	1.87	3.41	2.08	3.1	27.85	2.22	13.55	24.11
Average ANN MLP	1.02 (0.30)	1.61 (1.19)	2.14 (0.79)	10.9 (7.80)	12.23 (9.22)	2.48 (1.47)	21.97 (9.29)	18.09 (11.2)
MLP Ensemble	1.02	2.82	1.88	2.86	8.12	1.09	2.4	5.88
ANN RBF best training	1.17	3.38	1.72	4.38	8.11	1.21	2.84	4.91
Average ANN RBF	1.12 (2.55)	28.1 (82.42)	2.16 (1.40)	19.44 (29.20)	11.49 (9.30)	3.10 (1.17)	19.91 (14.43)	15.28 (7.27)
RNNL	1.51	5.98	1.47	3.34	7.28	1.87	2.82	8.53

Tabella 1: Comparazione dei risultati (Sistemi di regolazione, monitoraggio e controllo degli impianti di climatizzazione)

L'inserimento dei dati aggiuntivi (come l'affluenza dell'edificio) influenza i vari modelli.

Sono stati considerati tre tipi diversi di dati esterni:

1. Informazioni sull'ora del giorno
2. Flag per un giorno feriale o non lavorativo
3. Numero di occupanti nell'edificio

Con questa modifica tutti i modelli, escluso il SARIMA, migliorano i loro errori in almeno uno dei due insiemi di test. In generale, l'informazione fornita dagli input aggiuntivi sembra aiutare i modelli non lineari nella predizione, **in Fig. 2 è evidente come le nuove informazioni aiutino a migliorare il segnale predetto**, si noti ad esempio come il picco presente intorno l'istante 100 scompaia nelle predizioni delle reti neurali, a differenza del modello SARIMA che non migliora la sua efficacia con i nuovi ingressi.

I risultati sperimentali hanno quindi mostrato che l'approccio sviluppato raggiunge un'accuratezza maggiore rispetto agli altri e più in generale ha mostrato di saper sfruttare maggiormente l'aggiunta di dati esterni, un fenomeno che merita certamente una maggiore analisi.

Lo sviluppo successivo si occuperà dello sviluppo di modelli che correlino i dati misurati (es. occupazione e dati climatici) **con i differenti tipi di consumi elettrici** (illuminazione, climatizzazione, prese) in modo tale da consentire una diagnostica più puntuale.




Fig 2: Comparazione modelli

(Sistemi di regolazione, monitoraggio e controllo degli impianti di climatizzazione)