



Agenzia Nazionale per le Nuove Tecnologie,
l'Energia e lo Sviluppo Economico Sostenibile



Ministero dello Sviluppo Economico

RICERCA DI SISTEMA ELETTRICO

Monitoraggio e modellazione innovativa di consumi elettrici in smart building

M. Annunziato, F. Lauro, C. Meloni, S. Pizzuti

Report RdS/2011/333

MONITORAGGIO E MODELLAZIONE INNOVATIVA DI CONSUMI ELETTRICI IN SMART BUILDING

M. Annunziato, C. Meloni, S. Pizzuti (ENEA)

F. Lauro (Università degli Studi della Calabria)

Novembre 2011

Report Ricerca di Sistema Elettrico

Accordo di Programma Ministero dello Sviluppo Economico – ENEA

Area: Razionalizzazione e risparmio nell'uso dell'energia

Progetto: Tecnologie "smart" per l'integrazione della illuminazione pubblica con altre reti di servizi energetici e loro ottimizzazione

Responsabile Progetto: Mauro Annunziato, ENEA.

Riferimenti

Questo rapporto tecnico si riferisce all'Accordo di Programma tra Ministero dello Sviluppo Economico ed ENEA, nel contesto della Ricerca di Sistema il cui obiettivo è il miglioramento del sistema elettrico nazionale sia in termini di nuove tecnologie che di efficienza energetica.

Il rapporto si inquadra nell'Area "Razionalizzazione e risparmio nell'uso dell'energia elettrica", nell'ambito del PAR 2010, in riferimento alla tematica di ricerca "Risparmio di energia elettrica nell'illuminazione pubblica" - Progetto 3.2.1, "Tecnologie smart per l'integrazione della illuminazione pubblica con altre reti di servizi energetici e loro ottimizzazione" - Task D "Sviluppo del sistema di predizione ed interazione della rete di edifici".

Il rapporto si focalizza in particolare sullo sviluppo di una metodologia di monitoraggio e modellazione dei consumi elettrici, oltre gli aspetti connessi alla utenza e ai fattori climatici, finalizzata alla gestione energetica di edifici nel settore terziario, con l'obiettivo di creare un approccio innovativo alla gestione di reti di edifici in grado di ottimizzarne i consumi energetici, rendendoli più efficienti.

Sommario

<u>1. INTRODUZIONE</u>	5
<u>2. METODOLOGIE</u>	6
<u>2.1. Il monitoraggio remoto</u>	6
<u>2.2. Tecniche di modellazione</u>	8
2.2.1. <u>Modellazione 'Naive'</u>	8
2.2.2. <u>Modellazione statistica</u>	8
2.2.3. <u>Regressione lineare</u>	8
2.2.4. <u>Reti neurali artificiali</u>	9
2.2.5. <u>Tecniche di ensembling</u>	10
<u>2.3. Diagnostica di condizioni anomale</u>	12
<u>2.4. Monitoraggio dell'affluenza</u>	13
2.4.1. <u>Il Data Base Presenze di Stanza (DPS)</u>	13
2.4.2. <u>Software</u>	15
<u>3. ANALISI SPERIMENTALE</u>	19
<u>3.1. Analisi dati</u>	19
<u>3.2. Setup sperimentale</u>	23
<u>3.3. Illuminazione</u>	24
<u>3.4. Forza elettromotrice</u>	28
<u>3.5. Condizionamento</u>	32
<u>3.6. Riepilogo</u>	38
<u>4. CONCLUSIONI E SVILUPPI FUTURI</u>	39
<u>Bibliografia</u>	40

1. INTRODUZIONE

Attività pregressa

La prima fase di sviluppo della ricerca (PAR 2007 e PAR 2008-2009) si è focalizzato sullo sviluppo di metodologie di modellazione predittiva, ottimizzazione e regolazione dell'intero sistema edificio-sistema di climatizzazione innovativa e delle utenze ad essa correlate, attraverso cui si intende cogliere l'ulteriore margine di efficienza ma anche garantire la competitività del sistema nel suo insieme.

Il documento "Modelli predittivi e soluzioni pilota per la diagnostica e controllo di smart buildings", autori M. Annunziato, M. Bosello, M. De Felice, C. Meloni, S. Pizzuti Report RdS/2011/257 ,

http://www.enea.it/it/Ricerca_sviluppo/documenti/ricerca-di-sistema-elettrico/climatizzazione-rinnovabili/rds-257.pdf illustra i risultati ottenuti articolati su tre punti base:

- la modellistica predittiva (task C1);
- la qualificazione sperimentale (task C1);
- la simulazione e diagnostica (task C2).

Dopo una introduzione sulle tecnologie più diffuse per la diagnostica e controllo degli edifici il rapporto ha descritto il lavoro svolto per il conseguimento dei due sotto-obiettivi (task C1 e C2).

La prima parte della ricerca (task C1) ha riguardato lo sviluppo di un modello predittivo della richiesta energetica per la climatizzazione (estate-inverno) di un edificio complesso. Il modello tiene conto delle componenti periodiche long e medium term (giornaliere, settimanali e stagionali) e delle componenti short term che hanno un carattere a corta predicibilità (variazioni rapide di richiesta dell'utenza, guasti, effetti climatici) e fa uso di predittori neurali e metodologie di evolutionary computation. Non si basa su predizioni teoriche (non ha lo scopo di progettare il sistema di climatizzazione, bensì quello di gestirlo), ma ricostruisce progressivamente nel tempo il profilo di utenza dell'edificio al fine di ottimizzarne la prestazione. Pertanto è stato elaborato/qualificato sulla base di dati sperimentali provenienti da un edificio reale. L'utilità del modello risiede sia nella regolazione ottimale che nella disponibilità di un potenziale profilo di produzione, base per una strategia di negoziazione della rete attiva con la rete elettrica esterna, passo molto importante per un sistema soggetto alla variabilità delle rinnovabili. Accanto alla climatizzazione è stato necessario estendere lo studio alle altre utenze energetiche in quanto strettamente correlate per gli aspetti della diagnostica e del controllo.

Nella seconda parte (task C2) fu identificata una metodologia di ottimizzazione fondata sia sullo sviluppo di una metodologia diagnostica e sia sulla ottimizzazione multiobiettivo della regolazione delle varie componenti di climatizzazione e di produzione energetica, interne ed esterne all'edificio, per ottenere la massima efficienza, il minimo impatto ambientale, la garanzia di funzionamento, il minimo costo di gestione.

Attività PAR 2010

In questo periodo (PAR 2010) le attività svolte hanno riguardato lo sviluppo di una metodologia di supervisione e controllo dei consumi elettrici ed energetici, oltre gli aspetti connessi alla utenza e ai fattori climatici, finalizzata alla gestione energetica di edifici nel settore terziario.

In particolare le attività hanno riguardato:

- metodologie
 - approccio a modelli diagnostici;
 - modellazione tramite reti neurali;
 - progettazione e sperimentazione di un sistema di analisi relativo all'affluenza negli edifici.
- analisi sperimentale
 - modellazione.

2. METODOLOGIE

Secondo quanto previsto dal piano annuale del PAR 2010, le metodologie messe a punto si riferiscono ai seguenti argomenti :

- I sistemi di monitoraggio remoto;
- l'implementazione di modelli innovativi per la stima dei consumi elettrici;
- la diagnostica di situazioni anomale;
- il monitoraggio dell'affluenza negli edifici.

2.1. Il monitoraggio remoto

La riduzione dei consumi energetici, in particolare quelli elettrici, negli edifici è un campo di forte interesse in quanto connesso al problema delle emissioni di gas serra: la quota di CO₂ emessa da questi ultimi ogni anno è pari al 15% delle emissioni totali mondiali (fonte World Research Institute).

La normativa a livello comunitario e nazionale è sempre più stringente nel contenimento energetico degli edifici, come dimostra la recente Direttiva Europea 2010/31/CE.

Attualmente ogni anno gli edifici di nuova costruzione ad elevate prestazioni energetiche e quelli esistenti riqualificati energeticamente rappresentano una quota pari al 2,5% del patrimonio immobiliare totale, mentre sulla restante parte degli edifici non viene effettuato alcun tipo di intervento di riqualificazione.

Agire sugli edifici esistenti, sviluppando una innovativa soluzione per renderli più efficienti, è l'obiettivo di questa attività. Il singolo edificio è un nodo di un sistema più complesso (la rete) ed essendo parte integrante di essa, indipendentemente dalle sue caratteristiche, può in modo più o meno efficace raggiungere i suoi obiettivi, quali l'efficienza energetica, attraverso la connessione con gli altri elementi; essa si basa sulla progettazione di una rete capillare di sensori su ogni singolo edificio che permette di remotizzare in tempo reale le informazioni acquisite.

Questo approccio si fonda su un sistema di controllo centralizzato del parco edilizio distribuito che potrebbe portare a notevoli risparmi energetici ed economici con costi di investimento contenuti essendo fondati principalmente su automazione ed intelligenza.

Il monitoraggio remoto costituisce il primo passo per lo sviluppo di una rete di edifici; conoscere l'intensità, il profilo e le criticità del consumo sono gli elementi fondamentali per pianificare una strategia di intervento competitiva su grandi reti di edifici. A questo scopo sono state individuate le informazioni necessarie che permettono di ottenere strategie di diagnosi efficaci, determinare i costi da affrontare in relazione alla vetustà e ai vincoli dell'edificio e quantificare il risparmio energetico/ambientale ottenibile dall'impiego di differenti strategie.

L'architettura di sistema ipotizzata (Figura 1) si basa sulla costruzione di una rete di sensori distribuita capillarmente all'interno di ogni stabile che costituisce il cluster di edifici. La rete di sensori permette il monitoraggio delle variabili che influenzano lo stato del sistema edificio in un determinato periodo di tempo:

- condizioni ambientali esterne;
- condizioni ambientali interne;
- consumi termici;
- consumi elettrici;
- presenza degli utenti (per edifici adibiti ad uso ufficio).

A valle dello strumento di misura è presente in ogni edificio un sistema di trasmissione che ha il compito di trasferire in tempo reale e in continuo i dati misurati ad un unico punto, la control room, “remotizzando” l’informazione.

Nella control room le informazioni sulle variabili vengono archiviate ed elaborate in un server (intelligenza remota). Il lavoro offre un contributo allo sviluppo del sistema di supervisione del comportamento energetico delle reti di edifici proprio in questo senso: vengono costruiti modelli per la stima dei consumi dell’edificio al variare delle grandezze monitorate che li influenzano, con finalità di sviluppo di logiche di diagnostica, di logiche di conduzione/gestione dell’edificio e di controllo remoto (segnalazione di comportamenti anomali e inefficienze o intervento diretto).




Fig. 1 – Ipotesi di gestione energetica di una rete di edifici

Le informazioni derivanti dall’elaborazione dei dati monitorati permettono al supervisore di individuare eventuali condizioni anomale (diagnostica) che possono derivare da una mancanza di manutenzione, da guasti o da cattiva gestione dell’edificio, e di rilevare eventuali inefficienze (ad es. strutturali) della gestione energetica dell’edificio attraverso il confronto con edifici “simili” per caratteristiche tecniche e condizioni al contorno. Se delle anomalie sono effettivamente presenti, il supervisore può agire o attraverso un controllo diretto sui singoli impianti da remoto (telecontrollo) o attraverso una gestione indiretta (telegestione) informando i diretti responsabili del singolo stabile, i quali si occuperanno poi dell’intervento sul campo.

Attraverso opportuni sistemi di automazione è possibile comandare in maniera “intelligente” e con ausili automatici gli impianti tecnologici, portando ad una loro gestione molto più semplice, razionale e con risparmi energetici e sui costi di gestione. Risulta più semplice controllare le procedure di utilizzo dell’edificio in quanto diviene possibile delegare le diverse operazioni. Inoltre, l’automazione di alcune operazioni garantisce che quanto deve essere eseguito lo sia fatto prontamente e correttamente.

2.2. Tecniche di modellazione

In questo paragrafo vengono descritte le 5 tecniche di modellazione che sono state applicate e confrontate nella fase sperimentale.

2.2.1. Modellazione 'Naive'

Per fornire un confronto significativo tra i diversi metodi considerati si introduce un modello "Naive". Questo tipo di modello serve infatti a quantificare i miglioramenti apportati da metodi sicuramente più sofisticati ed "intelligenti".

Per dati periodici un modello "Naive" può essere il seguente:

$$X_t = X_{t-s}$$

dove S è il periodo osservabile. Questo modello non fa altro che valutare il segnale al tempo t fornendo lo stesso valore osservato esattamente S istanti passati.

Nel nostro caso, essendo i dati campionati con frequenza oraria ed essendo la loro periodicità di tipo settimanale, il valore di S è pari a 168 (24 ore * 7 giorni). Quindi, ad esempio, per stimare il consumo del giorno lunedì 14 all'ora x verrà usato il valore misurato il giorno lunedì 7 alla stessa ora x.

2.2.2. Modellazione statistica

In questo settore applicativo uno dei modelli più comunemente utilizzati è quello del profilo orario medio settimanale. Ovvero, dai dati a disposizione si calcola per i diversi giorni della settimana il valor medio del flusso di traffico ora per ora, ottenendo così un profilo medio di 24X7=168 punti.

2.2.3. Regressione lineare

Una delle tecniche di modellazione dei consumi elettrici maggiormente utilizzata è l'Analisi di Regressione Lineare o Multivariata (o Lineare Multipla).

La Regressione formalizza e risolve il problema di una relazione funzionale tra variabili misurate sulla base di dati campionari estratti da un'ipotetica popolazione infinita. La formulazione generale nel caso Multivariato è la seguente:

$$Y_i = \beta_0 + \beta_1 X_{1i} + \beta_2 X_{2i} + \dots + \beta_k X_{ki} + u_i$$

in cui:

- Y_i è la variabile dipendente (da modellare);
- $X_{1i}, X_{2i} + \dots + X_{ki}$ sono le i-esime osservazioni di ciascuno dei k regressori;
- $\beta_0 + \beta_1 x_{1i} + \beta_2 x_{2i} \dots + \beta_k x_{ki}$ è la retta di regressione;
- β_0 è il valore atteso di Y quando tutte le X sono pari a zero;
- β_1 è il coefficiente angolare di X_1 , β_2 è il coefficiente angolare di X_2 (tenendo costanti gli X_k non presi in considerazione), etc.;
- u_i è l'errore statistico.

Da questa formulazione generale discende il caso semplificato (Lineare) applicato nel presente lavoro:

$$y_i = a + bx_i + \varepsilon_i$$

in cui la variabile dipendente y è legata da una relazione lineare alla variabile indipendente x , a cui si aggiunge una quantità casuale (ε).

Nel nostro caso la variabile y rappresenta la stima oraria del valore di consumo in esame; con la variabile x abbiamo scelto di indicare il numero di persone presenti nell'edificio a quella stessa ora, dato che è uno degli aspetti che maggiormente influenza l'andamento del consumo. Il problema della regressione si traduce nella determinazione dei coefficienti a e b in modo da esprimere al "meglio" la relazione funzionale tra y e x . In particolare, per la valutazione del coefficiente angolare b del modello si è utilizzata una function Excel che, in base ai valori di training di x e di y , restituisce il valore di b più appropriato. Il valore del coefficiente a è stato scelto quindi di conseguenza.

2.2.4. Reti neurali artificiali

Le reti neurali artificiali (RNA) sono modelli di calcolo che si ispirano al funzionamento di sistemi nervosi biologici per risolvere problemi di classificazione, modellazione e predizione di elevata complessità, ovvero dipendenti da un elevato numero di variabili ed altamente non lineari, e pertanto non risolvibili attraverso metodi algoritmici. Il meccanismo di determinazione dei parametri interni del modello viene comunemente indicato come 'addestramento'. Tale procedura è a tutti gli effetti un problema di ottimizzazione in cui si richiede di minimizzare l'errore tra il dato reale e quello stimato, ovvero si adotta un meccanismo di 'apprendimento tramite esempi' avendo a disposizione un set di dati del fenomeno che si vuole modellare.

Nel presente lavoro tali modelli sono stati implementati per realizzare modelli predittivi a breve termine (1 ora) di flussi di traffico veicolare urbano (numero veicoli/ora).

Le reti neurali artificiali (RNA) sono modelli di calcolo che si ispirano al funzionamento del cervello per risolvere problemi di classificazione, modellazione e predizione di elevata complessità, ovvero dipendenti da un elevato numero di variabili ed altamente non lineari, e pertanto non risolvibili attraverso metodi algoritmici. I primi studi di tali modelli risalgono agli anni 40 per proseguire fino ai gironi nostri. Da allora questi modelli sono stati applicati in settori che vanno dall'ingegneria alla sociologia, dalla medicina alla finanza, etc. etc.

L'unità di calcolo elementare di una RNA è il neurone (o nodo), in esso si possono identificare tre componenti principali:

- Un insieme di connessioni in ingresso, ciascuna delle quali viene caratterizzata tramite un peso reale che ne definisce efficacia e tipologia.
- Un sommatore, che calcola la somma pesata dei segnali d'ingresso.
- Una funzione d'attivazione, tipicamente non lineare, che ricevuto come ingresso il segnale calcolato dal sommatore, determina lo stato di uscita del neurone.




Fig.2 : modello di neurone artificiale

In termini matematici, indicando con x_i le componenti del vettore di ingresso, w_i i pesi sulle connessioni entranti del k-esimo neurone, l'uscita del neurone k-esimo, possiamo descrivere il comportamento di un neurone attraverso le seguenti equazioni:

$$y_k = \varphi(net_k - \theta_k) \quad (1)$$

Dove net_k è la combinazione lineare degli ingressi ed è chiamata input netto:

$$net_k = w^T x = \sum_{j=1}^n w_{jk} x_j \quad (2)$$

Nella (3.1) abbiamo indicato con θ_k il valore di soglia del k-esimo neurone, detto anche BIAS (Basic Input Attivation System), cioè il grado di "sensibilità" con cui il neurone risponde alle perturbazione dell'input netto e con $\varphi(\cdot)$ la funzione di attivazione. Ogni funzione monotona crescente e continuamente differenziabile, può rientrare tra queste, quella più comunemente utilizzata è il sigmoide:

$$\varphi(x) = \frac{1}{1 + \exp(-x)} \quad (3)$$

L'elemento che caratterizza i diversi tipi di RNA è la topologia delle connessioni dei neuroni. L'architettura più comunemente utilizzata è quella del tipo 'feed-forward'. In tale modello i neuroni sono organizzati a livelli: il primo è detto input layer perché riceve i vettori d'ingresso; poi vi sono uno o più strati nascosti (hidden layer) e uno di uscita (output layer). In tale tipo di rete neuroni prendono quindi il loro input solo dallo strato precedente, ed inviano il loro output solo allo strato seguente. Inoltre neuroni dello stesso strato non sono connessi tra loro. Il meccanismo di determinazione dei pesi delle diverse connessioni viene comunemente indicato addestramento. Tale procedura è a tutti gli effetti un problema di ottimizzazione in cui si richiede di minimizzare l'errore tra il dato reale e quello stimato, ovvero si adotta un meccanismo di 'apprendimento tramite esempi', ovvero un set di dati del fenomeno che si vuole modellare.




Fig.3 : modello di RNA feed-forward

2.2.5. Tecniche di ensembling

Con ensemble si intende un insieme di macchine d'apprendimento base i cui output vengono combinati per migliorare le prestazioni globali. La varietà di termini con cui in letteratura vengono chiamate le varie macchine, riflette l'assenza di una teoria unificata sui metodi di ensemble e il fatto che sia un campo di

ricerca ancora da esplorare sotto molti aspetti. Le ragioni per cui indagare sull'efficacia di questi metodi sta nei risultati sperimentali fino ad oggi ottenuti, supportati da argomentazioni teoriche [Breiman 1996].

I metodi di ensemble si possono dividere in due categorie: generativi e non generativi. Quelli non generativi cercano di combinare nel miglior modo possibile gli output delle macchine, mentre quelli generativi generano nuovi set di learner, in modo da generare fra essi delle diversità che possano migliorare le prestazioni globali.

Per quanto riguarda le tecniche non generative, in classificazione, per esempio, si utilizza la tecnica della votazione a maggioranza (major voting), eventualmente raffinata pesando i voti proposti dalle macchine. Si possono combinare gli output attraverso operazioni di media (Basic Ensemble Method) eventualmente pesata, mediana, prodotto, somma, oppure scegliendo il minimo o il massimo.

Un semplice modo di combinare insieme gli output delle RNA è quello di farne banalmente la media aritmetica. L'output del Basic Ensemble Method (BEM) è quindi così definito:

$$f_{\text{BEM}} = \frac{1}{n} \sum_{i=1}^n f_i(x)$$

Questo approccio può portare ad un miglioramento delle performance, sebbene non tenga conto del fatto che alcune reti potrebbero essere più accurate di altre. Il BEM presenta i vantaggi di essere facilmente comprensibile e implementabile, senza aumenti nei valori d'errore, come si è dimostrato in.

Una generalizzazione del BEM consiste nell'individuazione dei pesi per ogni output in modo da minimizzare l'MSE dell'ensemble. Il Generalized Ensemble Method (GEM) è definito come:

$$f_{\text{GEM}} = \sum_{i=1}^n \alpha_i f_i(x)$$

dove i pesi α_i vengono scelti in modo da minimizzare l'errore assoluto medio.

I metodi generativi provano a migliorare le performance del sistema tentando di utilizzare le diversità fra i learner. Per fare questo vengono generati diversi set con cui addestrare le macchine (tecnica di resampling), o viene manipolata diversamente l'aggregazione delle classi (tecnica di feature selection) o ancora si possono addestrare dei learner che si specializzano su parti specifiche del set di apprendimento (mixture of experts). Le tecniche di resampling, come il bootstrapping, consentono di generare nuovi set a partire da quello originale e vengono utilizzate nei metodi generativi Bagging e Adaboost.

Il bagging è un metodo di ensemble che prende il nome dall'unione delle parole Bootstrap AGGREGatING. La tecnica di bootstrapping su un database consiste nell'estrazione con rimpiazzo dei suoi elementi in modo da creare nuovi diversi training set. La probabilità di estrazione di ogni esempio, nel bagging, è uguale a quella degli altri. L'algoritmo base prevede la creazione di modelli per ogni training set e successivamente la combinazione delle varie stime sul test set attraverso un'operazione di media.

Avendo a disposizione il training set iniziale S si costruiscono p nuovi training set S_i estraendo da S con rimpiazzo. A partire da ognuno di questi nuovi training set si effettua un modello e successivamente si considera come modello quello ottenuto mediando le uscite




Fig.4 : bagging

La tecnica Adaboost deriva dal fatto che l'ensemble prevede il bootstrap adattivo, nel senso che possiede la capacità di adattarsi alle caratteristiche di difficoltà del training set.

L'idea centrale è quella di estrarre a caso un certo numero di esempi dal training set, assegnando successivamente una probabilità maggiore di estrazione per gli esempi più difficili da apprendere.

Inizialmente si addestra una prima macchina con un training set costruito mediante estrazione casuale con probabilità uguale per tutti gli esempi. Fatto ciò si aggiornano le probabilità di estrazione per il training set successivo aumentando quella degli esempi del set originale appresi peggio. Si genera un nuovo training set e si addestra una nuova macchina e così via. Sperimentalmente si è evidenziato che Adaboost può ridurre sia bias che varianza.

2.3. Diagnostica di condizioni anomale

In questa sezione vengono presentati i criteri per la diagnostica dei consumi anomali. Per consumo anomalo intendiamo un consumo che si discosta sia dal caso medio statistico sia dal modello che ne fornisce una stima nelle condizioni che vengono misurate (es. per una certa occupazione o con particolari condizioni climatiche).

Il sistema diagnostico è stato come un sistema di regole basate su logica fuzzy.

La logica fuzzy (o logica sfumata o logica sfocata) è una logica in cui si può attribuire a ciascuna proposizione un grado di verità compreso tra 0 e 1. È una logica polivalente, e pertanto un'estensione della logica booleana ed è fortemente legata alla teoria degli insiemi sfocati (fuzzy set). Con grado di verità o valore di appartenenza si intende quanto è vera una proprietà: questa può essere, oltre che vera (= a valore 1) o falsa (= a valore 0) come nella logica classica, anche pari a valori intermedi. Questo approccio ha il vantaggio di non dover impostare dei meccanismi a soglie (soggetti ad errori anche macroscopici) e fornisce un risultato con un certo grado di verità (o plausibilità).

Nel caso particolare sono stati definiti i seguenti criteri di warning

- W1 = Se lo scostamento tra la stima RNA e la misura è ALTO Allora WARNING
- W2 = Se lo scostamento tra il valore statistico e la misura ALTO Allora WARNING
- A = Se W1 E W2 Allora ALLARME

I criteri W1, W2 sono stati modellati attraverso opportuni fuzzy set che identificano in modo sfumato il grado di scostamento i quali sono stati composti per ottenere il valore di allarme finale, ovvero il grado di plausibilità di un consumo anomalo.

Tale criterio generale è stato applicato per i consumi elettrici definendo i fuzzy set per l'illuminazione, il condizionamento e la forza elettromotrice ottenendo quindi 3 tipi di allarmi : A_{ill} , A_{con} , A_{fem} i quali generano un allarme generico se uno dei 3 si attiva. Ovvero

A = Se A_{ill} O A_{con} O A_{fem} Allora ALLARME

Ad esempio, nel caso dell'illuminazione




Fig. 5 – diagnostica consumi di illuminazione

Nella zona 1 si otterrebbe un allarme con grado circa 0.5 (consumo abbastanza anomalo), nella zona 2 si otterrebbe un allarme con grado circa 0.8 (consumo fortemente anomalo), mentre nella zona 3 si otterrebbe un allarme con grado circa 0.1 (consumo normale) in quanto in linea con i consumi attesi dal modello neurale (BEM).

2.4. Monitoraggio dell'affluenza

Una delle informazioni più rilevanti per i modelli di stima dei consumi è l'affluenza, ovvero il numero delle persone presumibilmente presenti nell'edificio.

In particolare il sistema che si occupa del controllo degli edifici richiede di conoscere, ad intervalli periodici una serie di informazioni relative ad un certo numero di stanze preselezionate da un energy manager.

Tali informazioni sono:

1. Rilevazione accessi al centro e relativa elaborazione dati al fine di ricostruire la presenza media (teorica) di persone in ogni stanza selezionata dedotta dai dati dei cartellini di accesso.
2. Dati provenienti dagli utenti (votazioni di comfort, preferenze di settaggio della climatizzazione, segnalazioni discomfort, commenti di varia natura).

Queste informazioni sono inserite all'interno di un database pubblico ad accesso remoto (DPS - Database Presenze di Stanza).

Presso il centro ENEA Casaccia è presente il sistema di controllo accessi GEPAVV che registra l'accesso di tutti i dipendenti ai tornelli d'ingresso e che presenta i dati di accesso secondo la logica:

- MATRICOLA – Data/ora Entrata
- MATRICOLA – Data/ora Uscita
- MATRICOLA – Data/ora Mensa

2.4.1. Il Data Base Presenze di Stanza (DPS)

Il sistema controllo accessi utilizza un Database SqlServer 2003 su cui memorizza tutte le informazioni. Per la raccolta dei dati proveniente dai diversi sistemi, è stato sviluppato un database pubblico ad accesso remoto (Database Presenze di Stanza – DPS) sviluppato con tecnologia MySQL nel quale confluiscono anche i dati di accesso.

In una prima fase sperimentale sono monitorati solamente gli accessi dei dipendenti dell'unità UTTEI allocati nell'edificio F40.

Nel DPS sono presenti anche le associazioni matricola-edificio-piano-stanza al fine di permettere ai sistemi di monitoraggio e controllo di operare correttamente.




Fig. 6 – Architettura funzionale di acquisizione accessi




Fig.7 -: struttura del database DPS

2.4.2. Software

Sono state sviluppate componenti software con le seguenti funzionalità :

- Interrogare il sistema di rilevazione accessi ed inserire le informazioni nel DB DPS;
- Raccogliere e gestire tramite interfacce grafiche web dati di comfort ambientale proveniente dagli utenti (interfaccia utente).
- Gestire tramite interfacce grafiche web del DB DPS (interfaccia supervisore).
- Elaborare i dati di accesso




Fig. 8 – architettura funzionale

Ogni tipo di interrogazione scrittura dei dati accesso è stata implementata in SQL ed inserita negli appositi moduli software.

Ad esempio, la query tipo per leggere le informazioni dal DB Gepav è:

```
"select Id, Transito, Matricola, Data, Ora from timbrature"
```

e la query tipo per inserire le informazioni sul DB DPS è:

```
" insert into accessi(matricola,idaccessi,Time,Tipo) values (xxxxx)"
```

Le interfacce utente e supervisore sono state implementate in JSP alle quali si accede previa autenticazione login/password.




Fig.9 - pagina di accesso




Fig. 10 - interfaccia utente




Fig. 11 - interfaccia supervisore

Infine, è stato sviluppato un modulo software che elabora i dati di accesso che ad intervalli regolari (es. 15min.) per ogni stanza indica il numero medio di persone presenti nella stanza da cui si può ricavare il numero medio di persone nel piano e nell'edificio.

Tale software è stato implementato in linguaggio Java in modo tale da garantire la piena portabilità su ogni tipo di sistema operativo e in modo tale da integrarsi in modo ottimale nella piattaforma globale di monitoraggio e controllo (Task A).

3. ANALISI SPERIMENTALE

In base al monitoraggio si sono potuti analizzare i dati relativi ai consumi dell'edificio scelto e la disponibilità di un database di un monitoraggio durato un anno ha permesso di identificare criticità e mal funzionamenti dell'edificio. L'edificio in esame (edificio C59 ubicato nel C.R. ENEA 'Casaccia'), costruito negli anni '80, destinato ad uso ufficio (del settore terziario), è caratterizzato dall'appartenenza ad una classe energetica bassa per il quale sarebbe necessario predisporre una efficace manutenzione ordinaria, in modo da individuare per tempo guasti e malfunzionamenti.

Tale esperienza ha permesso di confermare l'esigenza secondo la quale un qualsiasi edificio debba essere fornito di un adeguato sistema di monitoraggio: in questo modo attraverso l'acquisizione dei dati in tempo reale è possibile individuare immediatamente le eventuali criticità ed intervenire tempestivamente con conseguente notevole risparmio energetico.

In questo capitolo vengono descritti l'implementazione e i risultati della modellazione energetica proposta. La modellazione è basata su Reti Neurali ed Ensembling di Reti Neurali e viene messa a confronto con quella offerta da altri tipi di tecniche (par. 2.2) : modello naive, modello statistico e modello regressivo lineare. Le stime effettuate si riferiscono a tre diverse tipologie di consumo: illuminazione, forza elettromotrice e condizionamento. Per ognuna di queste tipologie sono stati costruiti dei dataset di riferimento contenenti le informazioni necessarie ai fini della sperimentazione. Inoltre, è stata effettuata l'analisi preliminare dei dati per meglio comprendere le caratteristiche del fenomeno in questione.

3.1. Analisi dati

In Figura 12 si mostra l'andamento del consumo orario elettrico generale (dato da consumo illuminazione + consumo forza elettromotrice) dell'edificio "C59" relativo al mese di Settembre 2009. Come era prevedibile, i dati di consumo presentano una periodicità settimanale: per ogni settimana sono evidenti i valori più alti di consumo, relativi ai cinque giorni lavorativi, ed i rimanenti valori più bassi relativi invece alle ore notturne e al finesettimana.




Fig. 12 - Consumo generale orario nel mese Settembre 2009

In Figura 13 è illustrato l'andamento medio orario di consumo elettrico generale di tutti i giorni della settimana nel trimestre Settembre 2009 – Novembre 2009. I giorni lavorativi presentano un profilo di consumo piuttosto simile, in alcuni giorni (ad esempio, lunedì) più alto di altri (ad esempio, venerdì); nei weekend il valore di consumo è molto più basso rispetto a quello del resto della settimana ed assume un valore praticamente costante, pari a quello che si registra nelle ore notturne.




Fig. 13 - Consumo generale orario medio di tutti i giorni settimanali (periodo Settembre 2009 – Novembre 2009)

Un altro fattore che influenza fortemente i valori di consumo elettrico nell'edificio è la presenza del personale. A livello bibliografico sono ben pochi gli studi e le analisi effettuate sugli edifici adibiti ad uso di ufficio che correlano il peso dei consumi elettrici con l'utenza in genere (personale, addetti). Questo legame in realtà è da considerare con maggiore interesse, visto che la correlazione consumi elettrici-personale può incidere per circa un terzo sul totale dei consumi elettrici di un edificio del terziario. In Figura 14 ed in Figura 15 si mostrano, rispettivamente, l'andamento dell'occupazione del "C59" ed il consumo elettrico generale: si tratta di profili orari medi relativi ai giorni lavorativi nel trimestre Settembre – Novembre 2009.

A partire dal livello costante di consumo nelle ore notturne (che si aggira attorno ai 12 kW), il valore di consumo generale dell'edificio inizia a crescere nelle prime ore mattutine e in maniera sempre maggiore con l'arrivo del personale. Il valore più alto si verifica in media a metà mattina, quando l'edificio è maggiormente popolato.




Fig. 14 - Occupazione oraria media (giorni lavorativi Settembre 2009 - Novembre 2009)




Fig. 15 - Consumo generale orario medio (giorni lavorativi Settembre 2009 - Novembre 2009)

In corrispondenza della pausa pranzo il consumo diminuisce per poi aumentare nuovamente nel primo pomeriggio. Con la fine del turno lavorativo il valore di consumo decresce man mano fino ad assestarsi nuovamente sul valore di consumo notturno quando l'edificio è vuoto.

Il numero di dipendenti nell'edificio "C59" durante il periodo lavorativo varia normalmente tra 45 e 70. La relazione tra occupazione e domanda di energia è mostrata in Figura 16 ed in Figura 17 la relazione viene estesa anche all'ora del giorno.




Fig. 16 - Relazione tra occupazione dell'edificio e consumo elettrico generale




Fig. 17 - Relazione tra ora del giorno, occupazione dell'edificio e consumo elettrico generale

3.2. Setup sperimentale

L'approccio che viene proposto per la modellazione delle tre categorie di consumo elettrico del "C59" è basato sulle RNA: in particolare, la tipologia di Rete Neurale utilizzata è quella feed-forward ad uno strato nascosto, con un numero di input pari al numero delle variabili considerate di volta in volta in ingresso, un unico output che rappresenta la stima di consumo energetico, e 10 neuroni interni. Le simulazioni sono state eseguite in ambiente MATLAB (R2010a) sfruttando le function messe a disposizione dal Neural Networks Toolbox (versione 6.0.4) (Figura 18). Le funzioni di attivazione per il livello nascosto e per il livello di uscita sono quelle di default, tangente iperbolica (tansig) e lineare (purelin) rispettivamente.




Fig. 18 - Esempio di utilizzo dell'nntraintool di Matlab per il training delle RNA

Anche l'algoritmo di training è quello di default (Levenberg-Marquardt) e così pure i parametri che lo caratterizzano (μ iniziale 0.001, μ massimo 1010, criterio di stop al raggiungimento di 1000 epoche), ad eccezione della suddivisione dei dati di input e di output, che è stata così fissata: 90% per il training, 10% per la validazione. Sebbene l'algoritmo Levenberg-Marquardt possa richiedere grandi quantità di memoria (inconveniente a cui è possibile rimediare tramite alcuni accorgimenti che tuttavia fanno crescere il suo tempo d'esecuzione), esso è il metodo più veloce presente nel toolbox. I metodi ad alta prestazione come questo possono convergere da dieci a cento volte più velocemente degli algoritmi di backpropagation classici. Il Levenberg-Marquardt rientra nella categoria degli algoritmi di training "veloci" grazie all'utilizzo di una tecnica di ottimizzazione numerica standard, applicabile in virtù del fatto che la funzione di

performance è quadratica (caratteristica tipica del training delle reti feed-forward): in pratica il calcolo dell'Hessiano (contenente le derivate parziali seconde degli errori), necessario per l'aggiornamento dei pesi e dei bias, viene approssimato in una forma in cui basta calcolare semplicemente lo Jacobiano (che contiene le derivate prime degli errori). Per ogni test effettuato, caratterizzato da un particolare set di input, sono state realizzate 10 prove (training e testing) con le RNA appena descritte. Nella seconda parte della modellazione energetica proposta le prestazioni delle RNA vengono valutate come Ensemble. La tecnica di Ensemble utilizzata è quella più semplice, la BEM, che, come descritto nel Capitolo precedente, effettua una media aritmetica degli output delle RNA. In particolare, in questo caso i calcoli relativi all'Ensemble sono stati svolti, per ogni set di input considerato, a partire dalla combinazione degli output delle 10 RNA.

I criteri adoperati per confrontare le prestazioni dei modelli sono l'errore medio assoluto (MAE, mean absolute error) e l'errore massimo assoluto (MAX, maximum absolute error). In formule:

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i|$$

$$MAX = \max \left\{ |y_i - \hat{y}_i| \right\}_{i=1}^N$$

dove:

- y_i : consumo elettrico reale all'ora i ;
- $\hat{y}_i$: consumo elettrico stimato all'ora i ;
- $|y_i - \hat{y}_i|$: valore assoluto della differenza tra consumo elettrico reale e consumo elettrico stimato all'ora i (errore di stima assoluto);
- N : numero dei campioni orari di consumo.

Infine, si sottolinea che la dinamica dell'edificio (i valori di consumo stesso) non viene considerata tra i dati utilizzati in input: ciò permette di valutare sia l'influenza degli aspetti connessi all'utenza, sia l'influenza dei fattori climatici sull'andamento dei consumi elettrici.

3.3. Illuminazione

La prima tipologia di consumo su cui si effettua la sperimentazione è quella relativa all'illuminazione. I dati si riferiscono ad un periodo di 3 mesi che va da martedì 1 Settembre 2009 a lunedì 30 Novembre 2009, per un totale di 13 settimane (91 giorni, quindi 2184 campioni orari). Il dataset trimestrale è stato suddiviso in due parti: la prima consiste in 10 settimane ed è stata utilizzata per la calibrazione (training) dei modelli, la seconda, formata dalle restanti 3 settimane (prese una per ogni mese), è la parte di testing utilizzata per valutarne le performance. Al termine della fase di testing si ottengono perciò le stime orarie di consumo dovuto all'illuminazione riferite a queste 3 settimane. In Tabella 4.1 sono elencati i diversi tipi di test effettuati con RNA e BEM, ognuno dei quali è caratterizzato da un diverso set di input. In particolare, con il termine "id giorno" si indica un numero (da 1 a 7) che identifica il giorno della settimana, mentre per "flag" si intende un numero (1 o 0) che distingue i giorni feriali dai festivi. Metà degli esperimenti è stata condotta

considerando tutti i giorni nel trimestre di riferimento, l'altra metà invece tenendo conto dei dati relativi ai soli giorni lavorativi.

Test	Numero di input	Variabili in input
Test A	8	mese, giorno, ora, id giorno, flag, affluenza, radiazione globale, temperatura esterna
Test B	7	mese, giorno, ora, id giorno, flag, radiazione globale, temperatura esterna
Test C	4	flag, affluenza, radiazione globale, temperatura esterna
Test D	9	mese, giorno, ora, id giorno, flag, affluenza, radiazione globale, temperatura esterna, ora tramonto
Test E	4	mese, giorno, ora, id giorno (solo lavorativi)
Test F	5	mese, giorno, ora, id giorno, affluenza (solo lavorativi)
Test G	8	mese, giorno, ora, id giorno, affluenza, radiazione globale, temperatura esterna, ora tramonto (solo lavorativi)
Test H	7	mese, giorno, ora, id giorno, affluenza, radiazione globale, temperatura esterna (solo lavorativi)

Tab. 1 - Test effettuati consumo illuminazione

Le Tabelle che seguono illustrano i risultati ottenuti con i diversi modelli nel training (Tabella 2 e Tabella 3) e nel testing (Tabella 4 e Tabella 5). In particolare, per quanto riguarda le RNA, vengono riportati:

- valore medio dei MAE relativi alle 10 prove di ogni test effettuato e tra parentesi la corrispondente deviazione standard (misura della dispersione dei dati attorno al valore medio);
- il più grande dei MAX relativi alle 10 prove di ogni test effettuato.

Test	NAIVE	REGR LIN	STAT	RNA	BEM
Test A	2.60	1.45	1.25	1.02 (± 0.13)	0.88
Test B	2.60	1.45	1.25	1.06 (± 0.14)	0.93
Test C	2.60	1.45	1.25	1.35 (± 0.02)	1.34
Test D	2.60	1.45	1.25	0.98 (± 0.10)	0.85
Test E	2.87	1.54	1.22	1.10 (± 0.05)	1.01
Test F	2.87	1.54	1.22	1.11 (± 0.06)	1.00
Test G	2.87	1.54	1.22	1.02 (± 0.08)	0.89
Test H	2.87	1.54	1.22	1.05 (± 0.11)	0.94

Tab. 2 - Risultati training consumo illuminazione: MAE (kW)

Test	NAIVE	REGR LIN	STAT	RNA	BEM
Test A	18.23	7.47	5.48	6.49	4.61
Test B	18.23	7.47	5.48	5.61	4.20
Test C	18.23	7.47	5.48	7.45	7.30
Test D	18.23	7.47	5.48	6.03	4.45
Test E	18.23	7.47	5.48	5.21	4.11
Test F	18.23	7.47	5.48	5.21	4.24
Test G	18.23	7.47	5.48	5.70	4.57
Test H	18.23	7.47	5.48	6.21	4.35

Tab. 3 - Risultati training consumo illuminazione: MAX (kW)

Test	NAIVE	REGR LIN	STAT	RNA	BEM
Test A	2.32	1.28	1.04	1.30 (± 0.13)	1.04
Test B	2.32	1.28	1.04	1.45 (± 0.23)	1.17
Test C	2.32	1.28	1.04	1.28 (± 0.04)	1.26
Test D	2.32	1.28	1.04	1.54 (± 0.37)	1.13
Test E	2.95	1.37	0.97	1.37 (± 0.18)	1.14
Test F	2.95	1.37	0.97	1.30 (± 0.13)	1.10
Test G	2.95	1.37	0.97	1.32 (± 0.20)	0.98
Test H	2.95	1.37	0.97	1.22 (± 0.10)	0.95

Tab. 4 - Risultati testing consumo illuminazione: MAE (kW)

Test	NAIVE	REGR LIN	STAT	RNA	BEM
Test A	4.90	5.60	4.74	5.73	4.38
Test B	4.90	5.60	4.74	8.02	5.17
Test C	4.90	5.60	4.74	6.48	5.62
Test D	4.90	5.60	4.74	10.69	4.48
Test E	4.90	5.60	4.74	6.73	4.85
Test F	4.90	5.60	4.74	6.84	5.23
Test G	4.90	5.60	4.74	6.89	4.20
Test H	4.90	5.60	4.74	5.53	4.02

Tab. 5 - Risultati testing consumo illuminazione: MAX (kW)

Come previsto, tutti i modelli proposti presentano risultati migliori rispetto al modello Naive. Il modello Regressivo Lineare, essendo fortemente influenzato dall'occupazione dell'edificio, presenta prestazioni migliori, sia nel training che nel testing, quando si fa riferimento a tutti i giorni della settimana. Si osservi come nel testing per i modelli Statistico, RNA e BEM si ottengano risultati migliori considerando in generale i soli giorni lavorativi. E' interessante notare come il vero valore aggiunto delle Reti Neurali si abbia quando le si combina in Ensembling. Il risultato globalmente migliore lo si ottiene infatti proprio attraverso questa metodologia con la configurazione H (MAE = 0.95 kW, Tabella 4). In Figura 19 si illustra la stima di consumo corrispondente proprio al miglior risultato offerto dal BEM, confrontato con i valori reali di consumo elettrico. Nelle Figure successive si estende questo confronto anche alle stime di consumo dei modelli Statistico e Regressivo Lineare. Si osserva come il modello Statistico (Figura 20) segua meglio l'andamento del consumo reale rispetto al modello Regressivo Lineare (Figura 21), a conferma del valore di errore MAE inferiore (Tabella 4). Da tutte queste Figure si può osservare come l'Ensembling neurale riesca a seguire i picchi molto meglio rispetto a qualsiasi altro modello.




Fig. 19 - Comparazione risultati illuminazione: consumo reale e miglior stima di consumo ottenuta tramite BEM




Fig. 20 - Comparazione risultati illuminazione: consumo reale, modello statistico e BEM




Fig. 21 - Comparazione risultati illuminazione: consumo reale, modello regressivo lineare e BEM

3.4. Forza elettromotrice

I dati che vengono utilizzati si riferiscono allo stesso trimestre Settembre – Novembre 2009 cui fanno riferimento i dati nel caso dell'illuminazione. Anche il tipo di suddivisione del dataset per la fase di training e per quella di testing è identico. In Tabella 6 sono elencati i diversi tipi di test effettuati con RNA e BEM, ognuno dei quali è caratterizzato da un diverso set di input. Gli esperimenti sono stati condotti considerando tutti i giorni nel trimestre di riferimento.

Test	Numero di input	Variabili in input
Test A	11	mese, giorno, ora, id giorno, flag, affluenza, radiazione diffusa, radiazione diretta, radiazione globale, temperatura esterna, ora tramonto
Test B	6	mese, giorno, ora, id giorno, flag, affluenza
Test C	1	affluenza
Test D	9	mese, ora, flag, affluenza, radiazione diffusa, radiazione diretta, radiazione globale, temperatura esterna, ora tramonto
Test E	10	mese, giorno, ora, id giorno, flag, radiazione diffusa, radiazione diretta, radiazione globale, temperatura esterna, ora tramonto

Tab. 6 - Test effettuati consumo forza elettromotrice

Le Tabelle che seguono illustrano i risultati ottenuti con i diversi modelli nel training (Tabella 7 e Tabella 8) e nel testing (Tabella 9 e Tabella 10).

Test	NAIVE	REGR LIN	STAT	RNA	BEM
Test A	2.09	1.60	1.45	1.01 (± 0.18)	0.80
Test B	2.09	1.60	1.45	0.90 (± 0.10)	0.76
Test C	2.09	1.60	1.45	1.51 (± 0.02)	1.49
Test D	2.09	1.60	1.45	1.03 (± 0.10)	0.87
Test E	2.09	1.60	1.45	1.16 (± 0.12)	0.88

Tab. 7 - Risultati training consumo forza elettromotrice: MAE (kW)

Test	NAIVE	REGR LIN	STAT	RNA	BEM
Test A	34.59	30.00	31.30	31.96	28.42
Test B	34.59	30.00	31.30	31.51	28.14
Test C	34.59	30.00	31.30	32.35	31.79
Test D	34.59	30.00	31.30	30.35	29.14
Test E	34.59	30.00	31.30	32.07	30.17

Tab. 8 - Risultati training consumo forza elettromotrice: MAX (kW)

Test	NAIVE	REGR LIN	STAT	RNA	BEM
------	-------	----------	------	-----	-----

Test A	1.51	1.17	1.38	1.01 (± 0.21)	0.68
Test B	1.51	1.17	1.38	1.01 (± 0.24)	0.80
Test C	1.51	1.17	1.38	1.26 (± 0.14)	1.25
Test D	1.51	1.17	1.38	1.02 (± 0.10)	0.74
Test E	1.51	1.17	1.38	1.16 (± 0.13)	0.79

Tab. 9 - Risultati testing consumo forza elettromotrice: MAE (kW)

Test	NAIVE	REGR LIN	STAT	RNA	BEM
Test A	12.40	6.50	7.50	8.15	4.49
Test B	12.40	6.50	7.50	8.88	4.07
Test C	12.40	6.50	7.50	11.94	7.95
Test D	12.40	6.50	7.50	10.39	5.57
Test E	12.40	6.50	7.50	12.34	5.19

Tab. 10 - Risultati testing consumo forza elettromotrice: MAX (kW)

In questo caso la bontà dei risultati di stima ottenuti ha fatto sì che non si andasse alla ricerca di ulteriori set di input che portassero a dei risultati migliori (ad esempio, considerando solo i giorni lavorativi nel periodo di riferimento, etc.). Il consumo elettrico relativo alla forza elettromotrice è risultato essere il più facilmente “modellabile”, probabilmente perché è quello più fortemente influenzato dalla presenza del personale in ufficio. Ciò è anche testimoniato dai dati di errore MAE di testing in Tabella 9: il modello regressivo lineare, che praticamente modella il consumo sulla base del dato di affluenza, presenta un MAE più basso di quello del modello statistico (nel caso dell’illuminazione avveniva il contrario). Il risultato globalmente migliore lo si ottiene anche in questo caso attraverso l’Ensemble di Reti Neurali con la configurazione A (MAE = 0.68 kW, Tabella 9). In Figura 22 si illustra la stima di consumo corrispondente proprio al miglior risultato offerto dal BEM, confrontato con i valori reali di consumo elettrico. In Figura 23 si estende questo confronto anche alla stima di consumo del modello statistico. Anche qui, come nel caso dell’illuminazione, si può osservare come l’Ensembling Neurale riesca a seguire i picchi del segnale reale molto meglio rispetto al modello statistico.




Fig. 22 - Comparazione risultati fem: consumo reale e miglior stima di consumo ottenuta tramite BEM




Fig. 23 - Comparazione risultati fem: consumo reale, modello statistico e BEM

3.5. Condizionamento

Il condizionamento, nonostante risulti per sua natura un fabbisogno di tipo termico, viene solitamente associato ad assorbimenti elettrici convenzionali in quanto le macchine delegate a questa funzione sono generalmente alimentate da fonte elettrica. La sperimentazione sul consumo relativo al condizionamento è stata effettuata su un lasso di tempo caratterizzato da clima estivo, in particolare compreso tra venerdì 19 Giugno 2009 e lunedì 31 Agosto 2009, per un totale di circa 10 settimane. Anche qui il dataset è stato suddiviso in due parti: la prima, consistente in circa 8 settimane, per la calibrazione (training) dei modelli; la seconda, formata dalle rimanenti 2 settimane (una a Luglio e una ad Agosto), per il testing dei modelli. In Tabella 11 sono elencati i diversi tipi di test effettuati con RNA e BEM, ognuno caratterizzato da un diverso set di input. In particolare, la dicitura “(-1)” o “(-2)” accanto alle variabili di input indica che sono stati considerati come input il valore della variabile corrispondente all’ora in esame e quello a un’ora o a due ore prima. Nel Test L, la dicitura “valori di consumo traslati di 3 ore” indica che il test è stato effettuato traslando tutti i dati consumo tre ore in avanti rispetto ai dati in input. Gli esperimenti sono stati condotti considerando tutti i giorni nel periodo di riferimento, ad eccezione del Test M in cui si tiene conto dei dati relativi ai soli giorni lavorativi.

Test	Numero di input	Variabili in input
Test A	10	mese, giorno, ora, id giorno, flag, affluenza, radiazione diffusa, radiazione diretta, radiazione globale, temperatura esterna
Test B	9	mese, giorno, ora, id giorno, affluenza, radiazione diffusa, radiazione diretta, radiazione globale, temperatura esterna
Test C	7	mese, ora, affluenza, radiazione diffusa, radiazione diretta, radiazione globale, temperatura esterna
Test D	7	mese, giorno, ora, id giorno, affluenza, radiazione diretta, temperatura esterna
Test E	6	mese, giorno, ora, id giorno, affluenza, temperatura esterna
Test F	5	affluenza, radiazione diffusa, radiazione diretta, radiazione globale, temperatura esterna
Test G	3	affluenza, radiazione diretta, temperatura esterna
Test H	10	mese, giorno, ora, id giorno, affluenza, radiazione diffusa, radiazione diretta, radiazione globale, temperatura esterna(-1), temperatura esterna
Test I	11	mese, giorno, ora, id giorno, affluenza, radiazione diffusa, radiazione diretta, radiazione globale, temperatura esterna(-2), temperatura esterna(-1), temperatura esterna
Test L	9	mese, giorno, ora, id giorno, affluenza, radiazione diffusa, radiazione diretta, radiazione globale, temperatura esterna (valori di consumo traslati di 3 ore)

Test M	3	affluenza, radiazione diretta, temperatura esterna (solo lavorativi)
Test N	3	temperatura esterna(-2), temperatura esterna(-1), temperatura esterna
Test O	9	mese, giorno, ora, id giorno, affluenza, radiazione diretta, temperatura esterna, consumo illuminazione, consumo prese
Test P	5	temperatura esterna(-2), temperatura esterna(-1), temperatura esterna, consumo illuminazione, consumo prese
Test Q	8	radiazione diretta(-2), radiazione diretta(-1), radiazione diretta, temperatura esterna(-2), temperatura esterna(-1), temperatura esterna, consumo illuminazione, consumo prese

Tab. 11 - Test effettuati consumo condizionamento

Le Tabelle che seguono illustrano i risultati ottenuti con i diversi modelli nel training (Tabella 12 e Tabella 13) e nel testing (Tabella 14 e Tabella 15).

Test	NAIVE	REGR LIN	STAT	RNA	BEM
Test A	6.70	4.32	4.70	1.78 (± 0.45)	1.32
Test B	6.70	4.32	4.70	1.99 (± 0.33)	1.57
Test C	6.70	4.32	4.70	2.61 (± 0.22)	2.35
Test D	6.70	4.32	4.70	1.98 (± 0.36)	1.60
Test E	6.70	4.32	4.70	1.87 (± 0.31)	1.51
Test F	6.70	4.32	4.70	3.62 (± 0.11)	3.51
Test G	6.70	4.32	4.70	3.73 (± 0.05)	3.67
Test H	6.70	4.32	4.70	1.93 (± 0.46)	1.57
Test I	6.70	4.32	4.70	1.92 (± 0.52)	1.51
Test L	6.70	4.32	4.70	2.03 (± 0.52)	1.60
Test M	6.79	4.37	4.47	3.61 (± 0.10)	3.53
Test N	6.70	4.32	4.70	3.86 (± 0.20)	3.72
Test O	6.70	4.32	4.70	1.89 (± 0.42)	1.48
Test P	6.70	4.32	4.70	3.71 (± 0.36)	3.46
Test Q	6.70	4.32	4.70	3.38 (± 0.13)	3.17

Tab. 12 - Risultati training consumo condizionamento: MAE (kW)

Test	NAIVE	REGR LIN	STAT	RNA	BEM
Test A	26.40	24.00	21.90	17.30	9.07
Test B	26.40	24.00	21.90	18.16	11.43
Test C	26.40	24.00	21.90	18.24	17.36
Test D	26.40	24.00	21.90	19.78	13.70
Test E	26.40	24.00	21.90	17.10	12.30
Test F	26.40	24.00	21.90	24.46	22.41
Test G	26.40	24.00	21.90	23.18	22.33
Test H	26.40	24.00	21.90	20.09	10.99
Test I	26.40	24.00	21.90	19.53	10.94
Test L	26.40	24.00	21.90	22.68	17.21
Test M	26.40	24.00	21.90	22.18	21.46
Test N	26.40	24.00	21.90	24.19	23.21
Test O	26.40	24.00	21.90	16.20	10.21
Test P	26.40	24.00	21.90	24.49	20.38
Test Q	26.40	24.00	21.90	23.65	19.87

Tab. 13 - Risultati training consumo condizionamento: MAX (kW)

Test	NAIVE	REGR LIN	STAT	RNA	BEM
Test A	4.76	3.78	4.06	4.00 (± 0.55)	3.20
Test B	4.76	3.78	4.06	3.45 (± 0.34)	2.95
Test C	4.76	3.78	4.06	3.28 (± 0.16)	3.09
Test D	4.76	3.78	4.06	3.59 (± 0.37)	3.10
Test E	4.76	3.78	4.06	3.92 (± 0.37)	3.11
Test F	4.76	3.78	4.06	3.23 (± 0.11)	3.12
Test G	4.76	3.78	4.06	3.26 (± 0.07)	3.18
Test H	4.76	3.78	4.06	3.70 (± 0.24)	3.30
Test I	4.76	3.78	4.06	3.63 (± 0.50)	3.26
Test L	4.76	3.78	4.06	3.65 (± 0.42)	3.03
Test M	3.05	4.53	4.73	3.89 (± 0.21)	3.85
Test N	4.76	3.78	4.06	3.45 (± 0.16)	3.30
Test O	4.76	3.78	4.06	3.81 (± 0.55)	3.31
Test P	4.76	3.78	4.06	3.45 (± 0.12)	3.21
Test Q	4.76	3.78	4.06	3.30 (± 0.16)	3.10

Tab. 14 - Risultati testing consumo condizionamento: MAE (kW)

Test	NAIVE	REGR LIN	STAT	RNA	BEM
Test A	14.84	12.00	13.00	17.27	9.11
Test B	14.84	12.00	13.00	15.55	8.69
Test C	14.84	12.00	13.00	13.07	10.40
Test D	14.84	12.00	13.00	17.54	9.30
Test E	14.84	12.00	13.00	22.81	12.14
Test F	14.84	12.00	13.00	11.09	10.34
Test G	14.84	12.00	13.00	11.44	10.67
Test H	14.84	12.00	13.00	17.17	10.25
Test I	14.84	12.00	13.00	15.83	9.82
Test L	14.84	12.00	13.00	16.22	11.14
Test M	9.52	13.60	13.00	13.98	10.35
Test N	14.84	12.00	13.00	12.84	11.94
Test O	14.84	12.00	13.00	18.67	10.53
Test P	14.84	12.00	13.00	16.75	11.29
Test Q	14.84	12.00	13.00	19.43	10.69

Tab. 15 - Risultati testing consumo condizionamento: MAX (kW)

Come è evidente dalle Tabelle, il numero di Test effettuati nel caso del consumo relativo al condizionamento è molto maggiore di quello delle due tipologie di consumo precedenti: sono state tentate diverse combinazioni di input al fine di riuscire a ottenere valori di errore più bassi possibile. I risultati finali tuttavia sono piuttosto lontani da quelli ottenuti per illuminazione e forza elettromotrice: il risultato globalmente migliore lo si ottiene anche in questo caso attraverso l'Ensemble di Reti Neurali con la configurazione B, ma con un MAE pari a 2.95 kW (Tabella 14), a differenza del MAE di illuminazione, 0.95 kW, e del MAE di forza elettromotrice, 0.68 kW. Il consumo elettrico relativo al condizionamento è risultato il più complesso da modellare, probabilmente perché è il più soggetto all'“arbitrio” umano. Ciò è confermato dai valori di errore piuttosto elevati ottenuti da tutti i modelli. Inoltre, un altro fattore che in questo caso è da considerare è l'inerzia dell'edificio. Dal grafico di Figura 24 si vede molto bene lo sfasamento del consumo di climatizzazione rispetto a tutte le altre variabili proprio a causa dell'inerzia. In queste condizioni si commette un errore di stima proprio dovuto allo sfasamento (errore che verrebbe rilevato come allarme diagnostico quando invece non dovrebbe). Per tener conto di questi aspetti dinamici, come abbiamo visto in alcuni test sono stati utilizzati in input i valori delle varie variabili (temperatura, radiazione diretta, radiazione globale) fino a due ore prima dall'ora considerata (vedi Test H, Test I, Test L, Test N, Test P e Test Q), tuttavia l'errore di stima commesso non è diminuito. Per questa particolare tipologia di consumo un input che molto probabilmente sarebbe stato determinante nel calcolo di una stima energetica accurata è la temperatura interna dell'edificio, di cui purtroppo non è stato possibile disporre come dato.




Fig. 24 - Consumo condizionamento relativo a una settimana di Agosto 2009 con temperatura esterna, radiazione diretta e radiazione globale corrispondenti

In Figura 25 si illustra la stima di consumo corrispondente al miglior risultato offerto dal BEM, confrontato con i valori reali di consumo elettrico. In Figura 26 si estende questo confronto anche alla stima di consumo del modello statistico. A differenza delle due tipologie di consumo precedenti, l'Ensembling Neurale presenta in questo caso maggiori difficoltà nell'inseguimento dei picchi del segnale reale di consumo ma le sue prestazioni restano comunque migliori di quelle del modello statistico.




Fig. 25 - Comparazione risultati condizionamento: consumo reale e miglior stima di consumo ottenuta tramite BEM




Fig. 26 - Comparazione risultati condizionamento: consumo reale, modello statistico e BEM (ens)

3.6. Riepilogo

In Tabella 16 si riportano, per ogni tipologia di consumo, i set di input che permettono all'Ensembling di Reti Neurali di ottenere le migliori prestazioni nella stima, con i relativi risultati del training e del testing.

Tipologia Consumo	Variabili in input	RNA				BEM			
		TRAIN		TEST		TRAIN		TEST	
		MAE	MAX	MAE	MAX	MAE	MAX	MAE	MAX
Illuminazione	mese, giorno, ora, id giorno, affl., rad. globale, temp. esterna (solo lavorativi)	1.05 (± 0.11)	6.21	1.22 (± 0.10)	5.53	0.94	4.35	0.95	4.02
FEM	mese, giorno, ora, id giorno, flag, affl., rad. diffusa, rad. diretta, rad. globale, temp. esterna, ora tramonto	1.01 (± 0.18)	31.96	1.01 (± 0.21)	8.15	0.80	28.42	0.68	4.49
Condizionamento	mese, giorno, ora, id giorno, affl., rad. diffusa, rad. diretta, rad. globale, temp. esterna	1.99 (± 0.33)	18.16	3.45 (± 0.34)	15.55	1.57	11.43	2.95	8.69

Tab. 16 - Risultati migliori ottenuti con RNA e BEM per ogni tipologia di consumo (kW)

4. CONCLUSIONI E SVILUPPI FUTURI

In questo rapporto abbiamo presentato un approccio innovativo per la modellazione dei consumi elettrici (illuminazione, climatizzazione, forza elettromotrice) in modo tale da correlarli con dati misurati (es. occupazione e dati climatici) con il fine di effettuare una diagnostica dei consumi più accurata. In particolare l'approccio che abbiamo proposto si basa sull'ensembling di reti neurali e lo abbiamo comparato con gli approcci comunemente usati nel settore. La sperimentazione ha riguardato la modellazione dei consumi elettrici di un edificio complesso del settore terziario ed i risultati hanno mostrato come l'approccio proposto sia sensibilmente più preciso rispetto a metodi tradizionalmente utilizzati di tipo statistico non adattivo.

Nella seguente tabella vengono riportati come risultati sintetici della sperimentazione gli errori medi assoluti a confronto ed il relativo guadagno di accuratezza.

	Metodo statistico (non adattivo)	Ensembling neurale	Guadagno relativo
Illuminazione	0.97	0.95	2%
f.e.m.	1.38	0.68	51%
condizionamento	3.78	2.95	22%
media	2.04	1.53	25%

Tabella 17 : sintesi accuratezza modelli (errori medi assoluti in kW)

Inoltre, è stata definita la diagnostica dei consumi anomali del singolo edificio basata sul confronto tra dato misurato e dato atteso stimato dai modelli sviluppati.

E' stato sviluppato ed implementato il sistema software per l'acquisizione e l'elaborazione degli accessi al centro, elemento fondamentale per poter effettuare una modellazione accurata dei consumi energetici.

Come sviluppi futuri, da un punto di vista metodologico è possibile raffinare la modellazione cercando di comporre i diversi modelli in modo opportuno in modo tale da arrivare ad un modello ibrido che riesca a cogliere gli aspetti migliori dei singoli modelli.

Dal punto di vista sperimentale, pensiamo di testare i metodi proposti anche su altri edifici del C.R. ENEA Casaccia (F40) e di estendere le metodologie proposte al caso di reti di edifici.

Infine, parte di tale lavoro è stato anche pubblicato e presentato al CONGRESSO NAZIONALE AICA 2011 (<http://congressoaica2011.polito.it/>)

Annunziato M. , Lauro F. , Moretti F. , Pizzuti S. " Modellazione di consumi elettrici attraverso Ensembling di reti neurali".

Bibliografia

K. A. Baumert, T. Herzog, J. Pershing. Navigating the Numbers Greenhouse Gas Data and International Climate Policy. World Resources Institute, 2005.

United Nations Environment Programme, Buildings Can Play Key Role In Combating Climate Change, 2007. <http://www.unep.org/Documents.Multilingual/Default.asp?DocumentID=502&ArticleID=5545&I=en>.

IEA (International Energy Agency). Electricity/Heat Data for IEA Europe. 2008.

L. Pedersen. Use of different methodologies for thermal load and energy estimations in buildings including meteorological and sociological input parameters. Renewable and Sustainable Energy Reviews, Elsevier 11 (2007) 998 - 1007.

M. Aydinalp, V. I. Ugursal e A. S. Fung. Modelling of residential energy consumption at the national level. International Journal of Energy Research 27 (2003) 441 - 453.

A. Rabl e A. Rialhe. Energy signature models for commercial buildings: test with measured data and interpretation. Energy and Buildings, Elsevier 19 (1992) 143 - 154.

M. Caldera, S. P. Corgnati e M. Filippi. Energy demand for space heating through a statistical approach: application to residential buildings. Energy and Buildings, Elsevier 40 (2008) 1972 – 1983.

H. Farahbakhsh, V. I. Ugursal e A. S. Fung. A residential end-use energy consumption model for Canada. International Journal of Energy Research 22 (1998) 1133 - 1143.

C. P. Bowers, T. Schnier, J. Wright e M. De Felice. Evolving a dynamic building thermal model using energy consumption data. Building and Environment (2010).

J. F. Kreider e X. A. Wang. Artificial neural networks demonstrations for automated generation of energy use predictors for commercial buildings. ASHRAE Transactions 97(1) (1992) 775 – 779.

J. F. Kreider e X. A. Wang. Improved artificial neural networks for commercial building energy use prediction. Solar Engineering ASM 1 (1992) 361 – 366.

M. Anstett e J. F. Kreider. Application of neural networking models to predict energy use. ASHRAE Transactions 99(1) (1993) 505 – 517.

R. Dodier e G. Henze. Statistical analysis of neural network as applied to building energy prediction. Proceedings of the ASME ISEC, San Antonio, TX (1996) 495 – 506.

G. K. F. Tso e K. K. W. Yau. Predicting electricity energy consumption: a comparison of regression analysis, decision tree and neural networks. Energy, Elsevier 32 (2007) 1761 - 1768.

S. L. Wong, K. K. W. Wan e T. N. T. Lam. Artificial neural networks for energy analysis of office buildings with daylighting. Applied Energy, Elsevier 87 (2010) 551 - 557.

E. Jadraque Gago, J. Ordonez Garcia e A. Espin Estrella. Development of an energy model for the residential sector: electricity consumption in Andalusia, Spain. Energy and Buildings, Elsevier 43 (2011) 1315 - 1321.

L. G. Swan, V. I. Ugursal e I. Beausoleil-Morrison. Occupant related household energy consumption in Canada: estimation using a bottom-up neural network technique. Energy and Buildings, Elsevier 43 (2011) 326 - 337.

E. Azar e C. Menassa. A conceptual framework to energy estimation in buildings using agent based modeling. Proceedings of the 2010 Winter Simulation Conference.

M. A. Arbib. The Handbook of Brain Theory and Neural Networks. The MIT Press, Cambridge (MA) (1995).

S. Haykin. Neural Networks, a comprehensive foundation (2nd edition). Prentice Hall, New Jersey (1999).

W. S. McCulloch, W. Pitts. A Logical Calculus of Ideas Immanent in Nervous Activity. Bull. Mathematical Biophysics 5 (1943) 115-133.

R. Rosenblatt. Principles of Neurodynamics. Spartan Books, New York (1962).

D. E. Rumelhart, J. L. McClelland. Parallel Distributed Processing: Exploration in the Microstructure of Cognition. MIT Press, Cambridge, Mass (1986).

M. T. Hagan, H. B. Demuth, M. Beale. Neural Network design. (1996).

A. K. Jain, J. Mao, K. M. Mohiuddin. Artificial Neural Networks: A Tutorial. Computer, vol. 29 no. 3 (1996) 31 - 44.

L. Breiman. Bagging predictors. Machine Learning, 24 (1996) 123 - 140.

G. Valentini e F. Masulli. Ensembles of learning machines. In R. Tagliaferri e M. Marinaro, editors, Neural Nets Wirtz Vietri-02, LNCS 2486 (2002) 3 - 19 Heidelberg (Germany). Series Lecture Notes in Computer Sciences, Springer-Verlag.

M. P. Perrone e L. N. Cooper. When networks disagree: ensemble methods for hybrid neural networks. Neural Networks for Speech and Image Processing by R.J. Mammone, ed. Chapman-Hall (1993).

Rosen B. E. Ensemble learning using decorrelated neural networks. Connection Science, 8, 3 - 4 (1996) 373 - 384.

R. Kohavi e E. Bauer. An empirical comparison of voting classification algorithms: Bagging, boosting and variants. Machine Learning, 36 (1999) 105 - 142.

Z. Baratacouglu e E. Alpaydin. A comparison of model aggregation methods for regression. In Okay Kaynak, Ethem Alpaydin, Erkki Oja e Lei Xu, ed., ICANN, Lecture Notes in Computer Science, Springer 2714 (2003) 76 - 83.

H. Drucker. Improving regressors using boosting techniques. In Douglas H. Fisher, ed., ICML, Morgan Kaufmann (1997) 107 - 115.

R. Avnimelech e N. Intrator. Boosting regression estimators. Neural Computation, 11 (1999) 491 - 513.

M. Krarti. Energy Audit of Building Systems: An Engineering Approach (2nd edition). CRC Press, Taylor & Francis Group (2011).

B. Kosko : Neural networks and fuzzy systems. Prentice-Hall, Englewood Cliffs (NJ) (1992).

H.J. Zimmerman : Fuzzy set theory. Kluwer Academic, Boston (1991).